

VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ

Fakulta elektrotechniky  
a komunikačních technologií

DIPLOMOVÁ PRÁCE



**VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ**

BRNO UNIVERSITY OF TECHNOLOGY

**FAKULTA ELEKTROTECHNIKY  
A KOMUNIKAČNÍCH TECHNOLOGIÍ**

FACULTY OF ELECTRICAL ENGINEERING AND COMMUNICATION

**ÚSTAV BIOMEDICÍNSKÉHO INŽENÝRSTVÍ**

DEPARTMENT OF BIOMEDICAL ENGINEERING

**TERAPEUTICKÁ HRA PRO MĚŘENÍ REAKČNÍ DOBY S  
VYUŽITÍM PLATFORMY BITALINO**

THERAPEUTIC GAME FOR REACTION TIME MEASUREMENT USING THE BITALINO PLATFORM

**DIPLOMOVÁ PRÁCE**

MASTER'S THESIS

**AUTOR PRÁCE**

AUTHOR

**Bc. Cindy Veselá**

**VEDOUCÍ PRÁCE**

SUPERVISOR

**Ing. Branislav Hesko**

**BRNO 2020**

# Diplomová práce

magisterský navazující studijní obor **Biomedicínské a ekologické inženýrství**

Ústav biomedicínského inženýrství

**Studentka:** Bc. Cindy Veselá

**ID:** 185959

**Ročník:** 2

**Akademický rok:** 2019/20

**NÁZEV TÉMATU:**

## **Terapeutická hra pro měření reakční doby s využitím platformy BITalino**

### **POKYNY PRO VYPRACOVÁNÍ:**

Cílem semestrální práce je vytvořit jednoduchou terapeutickou hru pro měření reakční doby na různé herní podněty generované v náhodném čase a s využitím biologických signálů snímaných v reálném čase. 1) Nastudujte si problematiku reakční doby a způsobů jejího měření. 2) Vytvořte literární rešerš na téma terapeutických počítačových her a snímání biologických signálů v reálném čase. 3) Implementujte snímání signálů v reálném čase s využitím platformy BITalino a diskutujte dosažené parametry snímání. 4) Implementujte terapeutickou hru schopnou vytvářet podněty v náhodných okamžicích. 5) Navrhněte a vytvořte metodu schopnou detekovat reakční dobu na základě biologických signálů. Ověřte na skupině probandů. 6) Vhodným způsobem zhodnoťte měření reakční doby. K vypracování semestrálního projektu je potřebné splnit body 1) až 3).

### **DOPORUČENÁ LITERATURA:**

[1] CHOWDHURY, Rubana, Mamun REAZ, Mohd ALI, Ashrif BAKAR, K. CHELLAPPAN a T. CHANG. Surface Electromyography Signal Processing and Classification Techniques. Sensors. 2013, 13(9), 12431-12466. DOI: 10.3390/s130912431. ISSN 1424-8220.

[2] AL SWEIGART. Making games with Python & Pygame a guide to programming with graphics, animation, and sound. Charleston, S. C: Creative Commons, 2012. ISBN 9781469901732.

**Termín zadání:** 3.2.2020

**Termín odevzdání:** 29.5.2020

**Vedoucí práce:** Ing. Branislav Hesko

**prof. Ing. Ivo Provazník, Ph.D.**  
předseda oborové rady

### **UPOZORNĚNÍ:**

Autor diplomové práce nesmí při vytváření diplomové práce porušit autorská práva třetích osob, zejména nesmí zasahovat nedovoleným způsobem do cizích autorských práv osobnostních a musí si být plně vědom následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č.40/2009 Sb.

## ABSTRAKT

Tato diplomová práce se zabývá snímáním elektromyografického signálu a detekcí svalové aktivity v reálném čase za účelem měření reakční doby. Pro motivaci pacientů byla navržena a implementována terapeutická závodní hra ovladatelná svalovou aktivitou. V práci byly pro detekci svalové aktivity zrealizovány tři různé metody, přičemž nejpřesnější výsledky dosahuje navržená neuronová síť s hierarchií U-Net, jež klasifikuje vzorky EMG signálu do dvou kategorií – klidové úseky a úseky reprezentující svalovou aktivitu. Přesnost klasifikace signálu touto metodou je 97 %. Následně byly zkoumány rozdíly reakčních dob mezi skupinami probandů, při různých podnětech a také zlepšení reakčních časů v průběhu hraní hry.

## KLÍČOVÁ SLOVA

Terapeutická hra, biofeedback, EMG, reakční doba, BITalino, Python

## ABSTRACT

This master's thesis focuses on real-time detection of activity in electromyographic signal for reaction time measurement. For patients motivation there was designed and implemented therapeutic car game controlled through the muscle activity. In this thesis were used three different algorithms for muscles activity detection in EMG signal. The best accuracy of this three methods has designed artificial network with U-Net hierarchy, which is used to segment samples into two categories - samples of signal with activity and samples representing calm. Accuracy of this method is 97 %. Later there were examined differences between groups of probands, different stimulus and the changes of reaction time over time.

## KEYWORDS

Therapeutic game, biofeedback, EMG, reaction time, BITalino, Python

VESELÁ, Cindy. *Terapeutická hra pro měření reakční doby s využitím platformy BITalino*. Brno, 2020, 79 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta elektrotechniky a komunikačních technologií, Ústav biomedicínského inženýrství. Vedoucí práce: Ing. Branislav Hesko



## PROHLÁŠENÍ

Prohlašuji, že svou diplomovou práci na téma „Terapeutická hra pro měření reakční doby s využitím platformy BITalino“ jsem vypracovala samostatně pod vedením vedoucího diplomové práce a s použitím odborné literatury a dalších informačních zdrojů, které jsou všechny citovány v práci a uvedeny v seznamu literatury na konci práce.

Jako autorka uvedené diplomové práce dále prohlašuji, že v souvislosti s vytvořením této diplomové práce jsem neporušila autorská práva třetích osob, zejména jsem nezasáhla nedovoleným způsobem do cizích autorských práv osobnostních a/nebo majetkových a jsem si plně vědoma následků porušení ustanovení § 11 a následujících autorského zákona č. 121/2000 Sb., o právu autorském, o právech souvisejících s právem autorským a o změně některých zákonů (autorský zákon), ve znění pozdějších předpisů, včetně možných trestněprávních důsledků vyplývajících z ustanovení části druhé, hlavy VI. díl 4 Trestního zákoníku č. 40/2009 Sb.

Brno .....

.....

podpis autorky

## PODĚKOVÁNÍ

Děkuji vedoucímu diplomové práce Ing. Branislavu Heskovi za účinnou metodickou, pedagogickou a odbornou pomoc a další cenné rady při zpracování mé diplomové práce.

Brno .....

.....

podpis autorky

# Obsah

<b>Úvod</b>	<b>11</b>
<b>1 ELEKTROMYOGRAFIE</b>	<b>12</b>
1.1 Vznik EMG signálu . . . . .	12
1.2 Typy snímaných signálů . . . . .	14
1.3 Elektrody . . . . .	14
1.4 Umístění elektrod . . . . .	15
1.5 Přístrojový zesilovač . . . . .	16
1.6 Vlastnosti EMG signálu . . . . .	16
1.7 Rušení signálu . . . . .	17
<b>2 BIOFEEDBACK</b>	<b>19</b>
2.1 Aplikace biofeedbacku . . . . .	19
2.2 Myofeedback . . . . .	20
2.3 Využití v klinické praxi . . . . .	21
2.4 Terapeutické hry využívající biofeedback . . . . .	21
<b>3 DETEKCE EMG SIGNÁLU</b>	<b>23</b>
3.1 Prahování, znaménkové změny . . . . .	23
3.2 TKEO operátor . . . . .	23
3.3 Vlnková transformace . . . . .	23
3.4 Empirická dekompozice signálu . . . . .	24
3.5 Metody strojového učení . . . . .	24
3.6 Metody umělé inteligence . . . . .	26
3.7 Konvoluční neuronové sítě . . . . .	28
3.8 Konvoluční sítě pro zpracování 1D signálů . . . . .	30
<b>4 REAKČNÍ DOBA</b>	<b>31</b>
4.1 Faktory ovlivňující reakční dobu . . . . .	32
4.2 Měření reakční doby . . . . .	33
4.3 Stanovení reakční doby z EMG signálu . . . . .	34
4.4 Využití reakční doby . . . . .	35
<b>5 BITALINO</b>	<b>36</b>
5.1 Technická specifikace BITalina . . . . .	36
5.2 EMG modul . . . . .	37

<b>6</b>	<b>IMPLEMENTACE HRY</b>	<b>38</b>
6.1	Menu . . . . .	38
6.2	Průběh hry . . . . .	39
<b>7</b>	<b>ZPRACOVÁNÍ SIGNÁLU</b>	<b>44</b>
7.1	Připojení BITalina a zobrazení signálu . . . . .	44
7.2	Zpracování signálu – TKEO operátor . . . . .	46
7.3	Zpracování signálu – metoda SVM . . . . .	46
7.4	Zpracování signálu – konvoluční neuronová síť . . . . .	47
<b>8</b>	<b>INTERPRETACE VÝSLEDKŮ</b>	<b>54</b>
8.1	Porovnání metod zpracování signálu . . . . .	54
8.2	Reakční doby . . . . .	56
<b>9</b>	<b>DISKUZE</b>	<b>66</b>
9.1	Dosažené parametry snímání . . . . .	66
9.2	Porovnání metod detekce aktivity v signálu . . . . .	67
9.3	Stanovení počátků aktivity v EMG signálu . . . . .	67
9.4	Srovnání reakčních dob v rámci hry . . . . .	68
	<b>Závěr</b>	<b>70</b>
	<b>Literatura</b>	<b>71</b>
	<b>Seznam symbolů, veličin a zkratk</b>	<b>79</b>

# Seznam obrázků

1.1	Akční potenciál [2]	12
1.2	Vznik EMG - signál vzniklý superpozicí [2]	13
1.3	Anatomie svalů dolní končetiny	15
2.1	Schéma biofeedbacku	19
3.1	Princip metody SVM [32]	25
3.2	Proces učení perceptronu [35]	27
3.3	Příklad struktury neuronové sítě [35]	27
3.4	Konvoluční neuronová síť [38]	28
3.5	Konvoluce vstupu s filtrem	28
3.6	Aktivační funkce ReLU [38]	29
3.7	„Pooling“ vrstva	29
4.1	Princip vzniku odpovědi na podnět [44]	31
4.2	Rozdělení reakční doby [43]	31
4.3	Závislost reakční doby na intenzitě podnětu a napětí svalu [47]	32
5.1	Funkční bloky BITalina typu „Plugged“ [56]	37
6.1	Menu hry	38
6.2	Nastavení - výběr metody	39
6.3	Pokyny pro hráče	39
6.4	Vývojový diagram inicializace hry	40
6.5	Semafor se zobrazenými pokyny	40
6.6	Průběh hry	41
6.7	Vývojový diagram průběhu hry	42
6.8	Vývojový diagram - pauza a ukončení hry	43
7.1	Vývojový diagram snímání signálu BITalinem	44
7.2	Vizualizace snímaného EMG signálu	45
7.3	Aplikace metody TKEO	46
7.4	Klasifikovaný signál metodou SVM	47
7.5	Struktura neuronové sítě U-Net	48
7.6	Operace „max pool“	49
7.7	Princip 1D transponovaného konvolučního operátoru	49
7.8	Manuálně anotovaná data	50
7.9	Predikce aktivity v EMG signálu metodou U-Net	52
7.10	Vstup neuronové sítě při real-time zpracování	52
7.11	Klasifikovaný signál metodou U-Net	53
8.1	Detekce počátku EMG aktivity jednotlivými metodami	55

8.2	Srovnání průměrných reakčních časů různých pohlaví . . . . .	59
8.3	Srovnání probandů hrajících a nehrajících počítačové hry . . . . .	59
8.4	Srovnání reakční doby u žen . . . . .	60
8.5	Srovnání reakční doby u skupiny mužů . . . . .	60
8.6	Srovnání reakční doby u skupiny prodandů hrající hry . . . . .	61
8.7	Srovnání reakční doby u skupiny prodandů nehrající hry . . . . .	61
8.8	Srovnání reakčních dob na různé podněty . . . . .	62
8.9	Srovnání reakčních dob při změnách barev semaforu . . . . .	63
8.10	Srovnání reakčních dob v jednotlivých hrách . . . . .	65
8.11	Zlepšení reakčních dob u jedinců hrajících a nehrajících hry . . . . .	65

# Seznam tabulek

1.1	Požadavky na elektromyograf [7] . . . . .	16
2.1	Efektivita léčby biofeedbackem některých onemocnění [12] . . . . .	21
5.1	Přehled parametrů BITalina [56] . . . . .	36
5.2	Parametry EMG modulu [56] . . . . .	37
8.1	Porovnání výsledků detekce aktivity v EMG různými metodami . . .	55
8.2	Přehled statistických testů [64] . . . . .	57
8.3	Průměrné reakční doby hráčů na různé podněty . . . . .	58
8.4	Průměrné reakční doby hráčů během jednotlivých her . . . . .	64
9.1	Porovnání metod pro stanovení počátků aktivity v EMG signálu . . .	69

# Úvod

Rychlost reakce hraje roli v každodenním životě všech z nás. Odpověď na podnět z okolního prostředí je často automatická, tudíž si ji při běžných situacích neuvedomujeme, avšak i přesto je nesmírně důležitá.

Doba od počátku stimulu po reakci probanda je nazývána jako reakční doba. Během této doby dochází k detekci a rozpoznání podnětu, zpracování informace, výběr vhodné odpovědi a přenos informace z centrální nervové soustavy do cílového (motorického) neuronu spojeného se svalem, jež vykoná příslušný pohyb. Pro detekci pohybu je v práci využito vzniku elektrické aktivity ve svalu. Princip vzniku elektromyografického signálu (EMG) a jeho snímání je popsáno v kapitole 1.

Signál snímáný v klidu pacienta však není nulový a je nutné jej odlišit od signálu vzniklého při svalové aktivitě. Pro detekci aktivity v EMG se v praxi využívá velkého množství metod, jejichž přehled je uveden v kapitole 3. V práci byly navrženy a naprogramovány tři rozdílné metody - metoda využívající zvýraznění signálu TKEO operátorem s následným prahováním, metoda strojového učení Support Vector Machine a neuronová síť.

V posledních letech dochází k rychlému rozvoji umělé inteligence a s tím narůstá také popularita těchto metod při řešení segmentačních problémů. Ve většině případů se však jedná o dvourozměrné signály – obrazy, nikoliv o jednorozměrné signály. V práci byla pro klasifikaci 1D signálu navržena a naprogramována konvoluční neuronová síť se strukturou U-Net. Síť segmentuje EMG signál na dvě skupiny – signál klidový a signál, v níž je přítomna svalová aktivita.

Rychlé reakce jsou velmi důležité například u řidičů, pilotů či sportovců, přičemž rychlost odpovědi závisí na obrovském množství faktorů. Faktory ovlivňující reakční dobu jsou součástí kapitoly 4. Jedním z těchto faktorů je trénovanost daného jedince, tudíž pro zlepšení reakční doby je možné využít například počítačových her.

Pro větší motivaci pacienta byla navržena a implementována terapeutická hra (viz. kapitola 6) založená na metodě zpětné biologické vazby – tzv. biofeedbacku. Biofeedbackem a jeho využitím v praxi se zabývá kapitola 2. V průběhu hry jsou pacientovi zobrazovány podněty, na které má účastník reagovat. Současně je snímán EMG signál, jež je v pozadí programu zpracováván a výsledek je vizualizován probandovi. Terapeutická hra byla testována celkem na 21 dobrovolnících, kteří odehráli pět po sobě jdoucích her. Při hře byl vždy snímán EMG signál a vyhodnocena reakční doba. Výsledky jsou statisticky zpracovány v kapitole 8 a následně diskutovány.




# 1 ELEKTROMYOGRAFIE

EMG neboli elektromyografie je lékařská vyšetřovací a terapeutická metoda, která je založena na záznamu elektrické aktivity vznikající při činnosti svalstva. Metoda poskytuje informaci jak o svalové funkci, tak i o funkci nervového systému a jejich vzájemném propojení. Elektromyografie má velmi široké spektrum využití, jež se nachází například při hodnocení pohybu, pro řízení myoelektrických protéz, ve sportovní medicíně či poúrazové terapii [1][2].

## 1.1 Vznik EMG signálu

EMG signál vzniká při svalových kontrakcích. Jsou rozlišovány tři druhy svalů – kosterní, hladké a srdeční, přičemž hlavní stavební jednotkou svalu jsou svalové vlákna neboli myofibrily. Člověk může vědomě ovládat pouze svaly kosterní tvořené příčně pruhovanou svalovinou, která se vyznačuje přítomností dvou kontraktálních bílkovin – aktinu a myozinu. Vytvořením aktin-myozinového komplexu vzniká stah – kontrakce. Hlavním podnětem pro kontrakci svalu je impuls (akční potenciál), který vzniká v centrální nervové soustavě (CNS) [2][3].




Obr. 1.1: Akční potenciál [2]

Pro vysvětlení vzniku akčního potenciálu je důležité pochopení základů excitability buněk na molekulární úrovni. Mezi vnitřním a vnějším prostředím buňky

se nachází polopropustná membrána. V klidu, kdy je sval naprosto relaxovaný, je potenciál mezi vnitřním a vnějším prostředím buňky v rozmezí -80 až -90 mV. Po překročení prahu, který je nutný k podráždění buňky, dochází k depolarizaci, při níž dojde k výměně iontů mezi vnitřním a vnějším prostředím. Během depolarizace se akční potenciál velmi rychle změní až na hodnoty +30 mV. Následuje repolarizace, při které je obnovena činnost sodno-draselné pumpy, a hodnoty akčního potenciálu klesají zpět k hodnotám klidovým. Poslední fází je hyperpolarizace, kdy hodnoty klesnou pod hodnoty klidového potenciálu. Průběh akčního potenciálu je zobrazen na obrázku 1.1 [2][3].

Akční potenciál je z CNS veden odstředivou drahou až k neurosvalovému spojení. Propojení mezi nervovým zakončením a svalovým vláknem je uskutečněno nervosvalovou ploténkou, což je typ chemické synapse zajišťující přenos vzruchu [3]. Jeden neuron může inervovat více svalových vláken, ale jedno svalové vlákno může být inervováno maximálně jedním neuronem. Nejmenší komponenta, kterou je možné inervovat samostatně, se nazývá motorická jednotka (MU). Množství svalových vláken neboli velikost motorické jednotky, závisí na konkrétním svalu. Malé motorické neurony inervují relativně málo svalových vláken a slouží k jemnějším a přesnějším pohybům. Naopak čím větší MU jsou, tím jsou svaly výkonnější [2][3].



Obr. 1.2: Vznik EMG - signál vzniklý superpozicí [2]

Při snímání povrchového EMG jsou svalová vlákna v různé vzdálenosti a hloubce vůči elektrodám. Proto výsledný nasnímaný signál je sumační signál dané motorické jednotky (tzv. MUAP). Superpozici jednotlivých impulzů vytvářející EMG signál

z jedné motorické jednotky znázorňuje obrázek 1.2 [2][4].

## 1.2 Typy snímaných signálů

Podle typu záznamu můžeme EMG signály rozdělit do tří skupin. Prvním typem je nativní signál, který je snímán v klidu pacienta, tzn. při uvolnění svalů. Tento signál je při snímání EMG považován za šum [1].

Druhou skupinou je snímání signálu při zátěži. Signál je zaznamenáván při pohybu pacienta, přičemž amplituda EMG signálu závisí na velikosti svalové kontrakce, případně na velikosti motorické jednotky. Signál snímáný při zátěži lze porovnat se signálem nativním, a tím detekovat pohyb pacienta [1].

Třetí možností je snímání odezvy na stimulační impuls. Periferní nervy jsou stimulovány elektrickými impulzy vysílané stimulační elektrodou a následně je detekována odezva na tento impuls. Impulzy se liší amplitudou a dobou trvání, případně také frekvencí opakování těchto impulzů. Slouží pro vyšetření reflexního oblouku [5].

## 1.3 Elektrody

Pro záznam EMG signálu se využívají dva základní typy elektrod – jehlové a povrchové [5][7].

Jehlové neboli vpichové elektrody jsou elektrody o velmi malé ploše. Zaznamenávají signál z definovaného místa zevnitř svalu či svalového vlákna a mají vysokou citlivost. Při jejich použití se jedná o invazivní vyšetření. Využívají se při diagnostice či pro stimulaci svalů [5][7].

Pro neinvazivní snímání slouží povrchové elektrody a aplikace těchto elektrod na kůži pacienta je velmi jednoduchá a rychlá. Dnes se standardně využívají gelové elektrody obsahující vodivý gel, který zajišťuje vodivé spojení mezi kůží a elektrodou tím, že umožňují průchod iontů. Využití tohoto gelu snižuje impedanci, přičemž čím nižší impedance je, tím lepší je přenos snímaného signálu. Impedance také klesá se zvětšující se plochou elektrody [5][7].


Vodivost je možné zvýšit odmaštěním kůže např. alkoholem, případně odstraněním nerovností (např. chlupů) ze snímaného povrchu. Výhodou těchto elektrod je nízká cena a možnost neinvazivního vyšetření. Povrchovými elektrodami však není možné zaznamenat signál z konkrétního místa, nýbrž je vždy zaznamenán větší počet svalových vláken daného svalu. Povrchové elektrody se využívají v diagnostice a při terapiích. V rámci celé práce bude využit pro snímání tento typ elektrod [5][7].

## 1.4 Umístění elektrod

Správné umístění elektrod je jeden z nejdůležitějších kroků měření. Umístěním či posunem elektrody je ovlivněna amplituda signálu a také poměr signál - šum (tzv. SNR) [2][4].

U snímání EMG je převážně využíváno bipolární zapojení, které je založeno na záznamu rozdílu potenciálů mezi aktivní a referenční elektrodou. Celkový počet elektrod závisí na počtu snímaných kanálů. Referenční a aktivní elektrody jsou tedy v párovém počtu a vždy k nim musí být zapojena elektroda zemnicí. V této práci je použito bipolární zapojení s využitím tří elektrod – jedna aktivní, jedna referenční a jedna zemnicí [2][4].

Jelikož aktivní elektroda zaznamenává elektrickou aktivitu svalu, je potřeba, aby byla co nejbližší danému svalu. V případě povrchových elektrod se umísťuje na bříško snímaného svalu. Referenční elektroda se umísťuje mimo aktivní sval, ale co nejbližší aktivní elektrodě. Naměřený signál je rozdíl potenciálů mezi těmito elektrodami. Jako referenční bod je využita třetí, zemnicí, elektroda [2][4][5].



Obr. 1.3: Anatomie svalů dolní končetiny

V práci je zaznamenáván pohyb dolní končetiny při sešlapávání pedálu. Při snímání signálu může pacient sedět, případně stát. Za pohyb chodila jsou zodpovědné svaly m. tibialis anterior, m. peroneus longus a m. gastrocnemius medialis či lateralis. Anatomie svalů dolní končetiny je znázorněna na obrázku 1.3. Každý sval má jinou funkci, přičemž za dorziflexi kotníku zodpovídá m. tibialis anterior, za ohyb kotníku jsou zodpovědné především svaly m. gastrocnemius. Elektrody pro snímání

signálu jsou umístěny na dolní končetině podle doporučení SENIAM, kdy pro měření aktivity svalu gastrocnemius lateralis má být aktivní elektroda umístěna v jedné třetině mezi hlavou fibuly a patou [6].

## 1.5 Přístrojový zesilovač

Jednou ze základních komponent celého snímacího systému je přístrojový zesilovač. Hlavní funkcí zesilovače je zvýšit úroveň signálu a potlačit nežádoucí rušení. Důležitými vlastnostmi přístrojového zesilovače je tedy zesílení a činitel potlačení souhlasného signálu CMRR (tzv. diskriminační činitel). Hodnota CMRR dosahuje u kvalitních zesilovačů až 120 dB. Výpočet CMRR je uveden rovnicí 1.1 [2][5].

$$CMRR = 20 \cdot \log \frac{A_{\text{rozdílové}}}{A_{\text{soufázové}}} \quad (1.1)$$

kde  $A_{\text{rozdílové}}$  je zesílení rozdílového signálu a  $A_{\text{soufázové}}$  je zesílení soufázového signálu.

Požadavky na elektromyograf pro snímání EMG signálu jsou shrnuty v tabulce 1.1 [5][7].

Tab. 1.1: Požadavky na elektromyograf [7]

Vlastnost	Minimální hodnoty
CMRR	80 dB
Vstupní impedance	10 MΩ
Zesílení	100-50000 x
Šířka přenášeného pásma	10-500 Hz

## 1.6 Vlastnosti EMG signálu

Elektromyografický signál, jak již bylo popsáno výše, je superpoziční signál z více motorických jednotek. Jedná se o stochastický (náhodný) signál, jehož model lze popsat rovnicí 1.2 [1].

$$x(n) = \sum_{r=0}^{N-1} h(r)e(n-r) + w(n) \quad (1.2)$$

kde  $x(n)$  je výsledný vzorek modelu EMG signálu,  $n$  jsou jednotlivé vzorky signálu,  $e(n)$  reprezentuje impuls motoneuronu,  $h(r)$  představuje MUAP,  $N$  je počet motorických jednotek a  $w(n)$  je bílý šum s Gaussovským rozložením [1].

Signál dosahuje amplitudy v rozmezí 20–5000  $\mu\text{V}$ , jež závisí především na snímaném typu EMG. Při nativním snímání se jedná o hodnoty do 300  $\mu\text{V}$ . Při zátěži, například při pohybu končetiny, amplituda signálu závisí na velikosti vyvinuté síly a konkrétním svalu (na množství motorických jednotek daného svalu), a amplituda signálu tak může dosahovat až jednotky  $\text{mV}$  [8]. Rozsah užitečných frekvencí je v pásmu od 6 do 500 Hz s maximem užitečného signálu od 20 do 150 Hz. Pro převod spojitého signálu na jeho digitální formu slouží elektronická součástka A/D převodník. Z Nyquistova teorému vychází, že vzorkovací frekvence musí být alespoň dvojnásobná vůči maximální snímané frekvenci. Vztah je vyjádřen rovnicí 1.3. Aby nedošlo k aliasingu, a tím k poškození užitečné části signálu, je u EMG signálů potřeba zvolit vzorkovací frekvenci 1000 Hz či vyšší [2][9].

$$f_{vz} > 2 \cdot f_{max} \quad (1.3)$$

kde  $f_{vz}$  je vzorkovací frekvence a  $f_{max}$  je maximální frekvence signálu.

## 1.7 Rušení signálu

Informace v této kapitole jsou převzaty ze zdrojů [1], [9] a [10]. Při záznamu EMG je současně zaznamenáno rušení různého charakteru. Pro analýzu EMG signálu je potřebné šum potlačit tak, aby při filtraci nedošlo ke zkreslení signálu, případně aby toto zkreslení bylo minimální. Šum vyskytující se v záznamech lze rozdělit na následující typy:

### Šum z elektronického zařízení

Všechna elektrická zařízení generují vlastní šum. Frekvence šumu jsou v rozmezí od nuly až do tisíců Hz, což postihuje veškeré užitečné frekvence EMG signálu. Širokopásmový šum je velmi obtížné filtrovat, a proto je snaha o maximální potlačení vzniku tohoto šumu. Pro eliminaci lze využít stříbrné či stříbro-chloridové elektrody, čímž je dosaženo vysoké stability a SNR je přijatelné.

### Síťové rušení

Jedná se o elektromagnetický šum (tzv. brum). Amplituda rušení je až třikrát větší než signál EMG. Brum v České republice má frekvenci 50 Hz, což zasahuje do užitečného spektra EMG signálu. Odfiltrvat lze pásmovou zádrží na dané frekvenci.

### **Pohybové artefakty**

Za vznik pohybových artefaktů může především pohyb elektrodového kabelu a rozhraní mezi elektrodou a kůží. Amplituda šumu má hodnoty obdobné jako EMG signál, avšak frekvence dosahují pouze do 10 Hz, tudíž šum není součástí užitečného pásma EMG signálu. Tento typ šumu lze odfiltrovat filtrem typu horní propusti.

### **„Cross-talk“**

Signál pocházející z měřeného svalu je kontaminován signály z jiných svalů. Cross-talk závisí na výběru elektrod, především na jejich velikosti, vzájemném odstupu, a také na směru vůči svalovým vláknům.

### **Elektrokardiografické artefakty**


Elektrická aktivita srdce může kontaminovat EMG signál snímáný ze svalů trupu.

### **Nestabilita EMG signálu**

Jak už bylo popsáno výše, EMG signál je náhodný. Frekvence do 20 Hz jsou většinou nestabilní, jelikož jsou ovlivněny rychlostí odezvy motorických jednotek na akční impulz.

## 2 BIOFEEDBACK

Biofeedback neboli biologická zpětná vazba se využívá pro terapeutické účely v různých medicínských oborech. Tato technika je založena na záznamu biologického signálu v reálném čase. Zpětná vazba je pacientovi sdělena nejčastěji vizuální či zvukovou formou. Úlohou pacienta je dosažení předem definovaného cíle. Schéma biofeedbacku znázorňuje obrázek 2.1. Pro větší motivaci pacienta jsou často implementovány hry, které jsou ovládány na základě vyhodnocení signálu. Účelem je zlepšení zdravotního stavu pacienta, ať už fyzického, duševního či emočního [11][12].



Obr. 2.1: Schéma biofeedbacku

### 2.1 Aplikace biofeedbacku

Biofeedback lze využít v různých medicínských odvětvích. Při terapiích jsou v závislosti na léčbě využívány rozdílné biologické signály. Biofeedback lze rozdělit na dvě základní techniky – přímý a nepřímý typ. Při využití tělesných vědomých reakcí, jako je například kontrakce svalu, se jedná o typ přímého biofeedbacku. Nepřímým typem je ovládání těch tělesných funkcí, kterých si pacient není vědom. Příkladem může být ovládání tepové frekvence [13].

Pro biofeedback lze využít různých senzorů či biologických signálů. Následně jsou popsány techniky, při kterých se v dnešní době biofeedbacku využívá, přičemž vždy záleží na účelu využití.



### **Elektroencefalografie (EEG)**

EEG biofeedback (neurofeedback) je založen na snímání elektrické mozkové aktivity. Jedná se o často využívanou formu terapie při léčbě epilepsie a poruch pozornosti (ADHD). Dále lze aplikovat u pacientů s poruchami spánku, paměti či s psychiatrickými onemocněními [12].

### **Respirace**

Pomocí hrudního pásu či elektrod je zaznamenáváno dýchání, které úzce souvisí s emočním stavem pacienta. Využívá se při léčbě respiračních onemocnění, dále pro zklidnění dechu, pro motivaci usilovného nádechu či výdechu. Biofeedback při dechových cvičeních se ukázal jako účinná léčba hypertenze [13][14].

### **Srdeční frekvence a její variabilita**

Tepová frekvence (TF) je zaznamenávána optickým snímačem či z elektrokardiogramu (EKG). Pacientovi je vizualizována často pouze hodnota tepové frekvence, jež je ovlivněna především emočním stavem pacienta. Při stresu dochází k jejímu zvyšování. Snímání tepové frekvence se v posledních letech rozšířilo do veřejnosti, jelikož odhad TF lze získat za pomoci mobilních aplikací či chytrých hodinek. Biofeedback založený na variabilitě TF v čase je vhodný doplněk při léčbě astmatu, či depresivních stavů [14].

### **Elektrodermální aktivita (EDA)**

Elektrodermální aktivita zaznamenává změnu vodivosti kůže, jež je ovlivněna pocením kůže. Technika nachází využití v odvětví psychiatrie či psychologie [13].

## **2.2 Myofeedback**

Povrchová elektromyografie (tzv. sEMG) je jedna z nejčastěji využívaných forem biofeedbacku. Zpětná vazba využívající elektromyografický signál se označuje jako myofeedback.

Myofeedback nachází využití jak v diagnostice, tak i v terapii. Pomocí myofeedbacku lze zjišťovat reakce pacienta na podněty z okolí. Jedná se o velmi rozšířenou klinickou metodu při rehabilitacích, určenou například pacientům s poruchami centrálního nervového systému (CNS) a pacientům s nemocemi či poraněním míchy [15].

Proband nemusí být schopen funkčních pohybů končetiny, ale stále má možnost aktivovat svaly, čímž vzniká také EMG signál [16]. V posledních letech se oblast využití rozšířila o robotické končetiny ovládané tímto signálem [17]. Mnoho uživatelů

myoelektrických protéz horních končetin má s ovládáním protézy značné problémy. Proto je vhodné, aby trénink začal ještě před operací protézy, a zároveň aby pokračoval i po operaci, dokud pacient kontrolu nad protézou neovládne [18].

## 2.3 Využití v klinické praxi

Biofeedback se při rehabilitacích aplikuje více než padesát let. Výhoda biofeedbacku oproti zpětné vazbě terapeuta v tom, že pacient zpětnou vazbu dostává neustále a informace jsou přesnější. Účinnost biofeedbacku pro různé onemocnění shrnuje tabulka 2.1 [12].

Tab. 2.1: Efektivita léčby biofeedbackem některých onemocnění [12]

<b>Efektivní</b>	<b>Pravděpodobně efektivní</b>	<b>Možná efektivní</b>	<b>Neprokázáno</b>
Inkontinence	Alkoholismus	Astma	Poranění míchy
Úzkost	Artritida	Autismus	Imunitní funkce
ADHD	Fekální inkontinence	Únavový syndrom	Poruchy příjmu potravy
Epilepsie	Bolest hlavy	Deprese	Synkopa
Pohybové nemoci	Nespavost	Bellova obrna	-
Hypertenze	Poranění mozku	Erektilní disfunkce	-

## 2.4 Terapeutické hry využívající biofeedback

Pro interpretaci signálu a větší motivaci pacientů jsou do systémů často implementovány hry. Senzor zaznamenává signál z pacienta, který je zpracován a následně vizualizován příslušnou změnou ve hře, kterou pacient může tímto způsobem ovládat. Vše se neustále opakuje, a podle úspěšnosti pacienta ve hře může být snížena či zvýšena obtížnost hry. Následně jsou uvedeny příklady her ovládaných různými typy biofeedbacku.

Pro neurofeedback bylo aplikováno velké množství různých her, které jsou ovládány především na základě pozornosti hráče. Hry jsou určeny například pro pacienty s mírnou kognitivní poruchou či poruchou pozornosti. Příkladem může být hra,

ve které postava má za úkol posbírat mince. Podle pozornosti pacienta se zvyšuje rychlost běhu postavy a při určité rychlosti je možné mince sesbírat. Dalším příkladem je hra, kde pacient mírou soustředění ovládá náladu dívky. Jinou hrou je hra „letadlo“, v níž se letadlo vzdaluje od překážek se zvyšující se pozorností hráče [19].

Pro starší dospělé pacienty byly vyvinuly hry pro zlepšení kognitivního výkonu ovládané pohyby těla, které ovládají postavu či objekt ve hře. Jedná se o hry, kde se hráč vyhýbá překážkám, sbírá či přesunuje objekty. Každá hra může mít konkrétní zaměření, např. pro koordinaci těla, vyvažování, či zdokonalení paměti [19].

Pro svalový trénink, kdy se pacient učí ovládat a kontrolovat pohyb, či zvýšit sílu, vytrvalost nebo koordinaci jsou implementovány hry založené na myofeedbacku. Existují různé typy her. Příkladem je hra, v níž hráč ovládá auto, které podle velikosti kontrakce končetiny zrychluje či zpomaluje. Nebo hra, kde hráč ovládá objekt tak, aby nenarazil do překážek. Je potřeba, aby ve správnou chvíli pacient sval uvolnil, případně sval zatnul [15].

Mezi další implementované hry pro myofeedback patří například hra „Pong“, která je mapována na jednu proměnnou. Hráč se snaží míček vždy odrazit od desky. Za každý odražený míček získává bod [20].

Pro výzkumné účely byla vyvinuta hra, kde je úkolem hráče odhalit obrázek posunováním kurzoru. Měří se čas, za který hráč odhalil celý obrázek. Hra může být ovládána pohyby jedné či obou končetin [16].

Další hry založené na myofeedbacku jsou pro pacienty před i po operaci myoelektrických protéz horních končetin. Hry slouží ke zlepšení koordinace svalů a celkové kontroly nad nimi. Účastníci podporují ovládání hry zdravou končetinou. První z her je závodní hra, kde EMG signálem proband ovládá zatáčení auta vpravo/vlevo a zdravou rukou pomocí klávesové zkratky ovládá zrychlování/brzdění auta. V další hře je cílem hráče projít labyrint a posbírat různé objekty, přičemž hra je ovládána pouze svalovou aktivitou. Pro přepínání směru pohybu v labyrintu hráč je nutná kontrakce svalu. Dalším příkladem je závodní hra, kde rychlost auta je dána intenzitou kontrakce a směr určuje, zda je končetina ve flexi či extenzi [18][21].

Pro trénink reakční doby byly vyvinuly hry, při nichž má hráč co nejrychleji stisknout správné tlačítko po vizualizaci určitého objektu na obrazovce. Jednou z těchto her je například zobrazování dopravních značek. U vyšších úrovní obtížnosti jsou implementovány značky, které nevyžadují žádnou reakci [22].

## 3 DETEKCE EMG SIGNÁLU

Existuje velké množství metod, které mohou být pro detekci aktivity v EMG signálu využity. Ty mohou být založeny například na jednoduchém či dvojitým prahování, vlnkové transformaci, empirickém rozkladu signálu či umělé inteligenci. Detekovat kontrakci svalu lze z filtrovaného či surového EMG signálu [1][23].

### 3.1 Prahování, znaménkové změny

Základní technikou detekce EMG aktivity je jednoduché prahování. Jedná se o jednoduchou metodu založenou na překročení předem stanoveného prahu ve filtrovaném signálu. Metoda silně závisí na stanovení prahové hodnoty [1].

Metoda detekce dvojnásobného prahu využívá surový signál. Úspěšnost metody je dán parametry jako jsou například pravděpodobnost detekce, pravděpodobnost chybné detekce a časové rozlišení. Dvuprahové detektory dosahují lepších výsledků než detektory s jedním prahem [24].

Když je sval aktivní, amplituda signálu se mění výrazně rychleji a současně dochází k častějším změnám znaménka signálu. Na základě tohoto poznatku lze také detekovat svalovou aktivitu [25].

### 3.2 TKEO operátor

Teager-Kaiser operátor (TKEO), je nelineární operátor, jež je založen na odhadu energie signálu. TKEO zahrnuje jak amplitudovou, tak i frekvenční složku svalové aktivity. Po aplikaci TKEO operátoru je zesílena energie vrcholů akčního potenciálu a tím pomáhá rozlišit EMG v klidu od aktivity a zlepšuje přesnost detekce. Pro detekci počátku svalové aktivity je výstup prahován. Diskrétní TKEO je definován funkcí popsanou v rovnici 3.1 [26].

$$\phi[x(n)] = x^2(n) - x(n+1) \cdot x(n-1) \quad (3.1)$$

kde  $x$  je signál a  $n$  je konkrétní vzorek signálu.

### 3.3 Vlnková transformace

Vlnková transformace WT (z angl. Wavelet Transform) je metoda, kterou lze využít pro analýzu či filtraci i nestacionárních signálů. Výstupem je časově-frekvenční po-

pis signálu. Spojitou vlnkovou transformaci lze interpretovat jako korelaci signálu s bázovými funkcemi (vlnkami) a je popsána rovnicí 3.2 [27].

$$y(a, b) = \frac{1}{\sqrt{a}} \int_{-\infty}^{+\infty} x(t) \psi \frac{(t - b)}{a} dt \quad (3.2)$$

kde  $a$  je dilatace vlnky,  $b$  je časový posun,  $\psi$  je mateřská vlnka,  $x(t)$  je vstupní signál a  $y(a, b)$  je výstup funkce.

Svalová aktivita je rozpoznávána na základě přítomnosti MUAP v signálu EMG. Motorické jednotky mají různé vzdálenosti od záznamových elektrod. MUAP se v signálu opakují, mají stejný tvar, ale různou šířku a amplitudu. Mateřská vlnka je určena podle daného EMG signálu. Výhodou je, že algoritmus lze realizovat v reálném čase [27].

### 3.4 Empirická dekompozice signálu


Empirická dekompozice signálu (EMD) je metoda založená na rozkladu různě složitých nestacionárních signálů. Výsledkem jsou takzvané modální funkce. Pro použití metody signál musí splňovat dvě základní podmínky. První podmínkou je, že rozdíl mezi počtem průchodů nulou a počtem extrémů je maximálně o jeden. Druhou podmínkou je, že průměrná hodnota z obálky lokálních maxim a obálky lokálních minim je nulová či velmi blízká nule [28].

### 3.5 Metody strojového učení

Mezi nejnovější přístupy se řadí metody umělé inteligence, které lze využít k identifikaci pohybu či rozpoznávání gest. Sít je nejdříve naučena na trénovacích datech. Model, který vznikl během tréninku, dokáže poznatky aplikovat na nová data. Existují různé varianty v závislosti na požadovaném výstupu sítě. Učení může probíhat s učitelem či bez učitele [29].

Strojové učení zahrnuje například metody shlukování, regrese nebo klasifikace. Většina metod strojového učení při fázi učení vyžaduje velké množství označených dat. Algoritmy nelze využít přímo na surová data. V rámci předzpracování signálu je nutné z dat extrahovat příznaky. Příznaky následně vytvoří příznakový prostor, který data reprezentuje. Extrakce příznaků je často velmi komplikovaná a časově náročná. Pro klasifikaci se využívají především metody SVM (z angl. Support Vector Machines) a naivní Bayesovský klasifikátor [30][31].

Metodu SVM lze využít pro klasifikační úlohy či pro regresi dat. Vstupem jsou jednotlivé extrahované příznaky. Pokud by byl problém omezen na dva příznaky ( $X$ ,  $Y$ ) se dvěma klasifikačními třídami a každý prvek by patřil do jedné z tříd, pak by obrázek 3.1 tento algoritmus vystihoval.  $H$  označuje optimální přímku,  $m$  maximální vzdálenost od obou tříd a  $W$  je normálový vektor k optimální přímce [32].



Obr. 3.1: Princip metody SVM [32]

Cílem SVM metody je najít takovou přímku, aby vzdálenost přímky  $H$  od obou tříd byla maximální. Přímka je nalezena ve fázi učení za pomoci matematických operací. Dokud není nalezeno optimum (maximální vzdálenosti od obou tříd) je přímka neustále upravována. Nová data jsou následně zařazena s využitím tohoto vzniklého modelu. V reálných systémech je však využíváno více příznaků, často i více tříd, čímž vzniká  $N$ -dimenzionální prostor [32].

## Extrahované příznaky v EMG signálu

Signál EMG se mění v závislosti na aktivitě svalu, což způsobuje změnu jednotlivých parametrů. Jednotlivé úseky signálu lze reprezentovat extrahovanými příznaky v časové, časově-frekvenční či frekvenční oblasti. Příznaky jsou vybrány tak, aby popisovaly signál co nejvýstižněji. Příznaky jsou počítány v klouzavém okně. Kombinací příznaků lze následně zařadit úsek signálu do příslušné kategorie. Následně jsou popsány vybrané extrahované příznaky, jež jsou převzaty ze zdroje [33] a [34].

### Střední absolutní hodnota (MAV)

Jedná se o jednoduchý způsob detekce svalové aktivity. Příznak je extrahovaný z časové oblasti signálu. MAV je průměr absolutní hodnoty signálu v klouzavém okně. Pro výpočet slouží vzorec 3.3.

$$MAV = \frac{1}{N} \sum_{k=1}^N |X_k| \quad (3.3)$$

kde  $X$  je EMG signál,  $k$  je prvek signálu a  $N$  je délka signálu.

### **Střední kvadratická hodnota (RMSE)**

Vyjadřuje energii signálu v časové oblasti. Výpočet je vyjádřen rovnicí 3.4.

$$RMSE = \sqrt{\frac{1}{N} \sum_{k=1}^N X_k^2} \quad (3.4)$$

kde  $X$  je EMG signál,  $k$  je prvek signálu a  $N$  je délka signálu.

### **Rozptyl signálu (VAR)**

Vztah je určen vzorcem 3.5.

$$VAR = \frac{1}{N-1} \sum_{k=1}^N X_k^2 \quad (3.5)$$

kde  $X$  je EMG signál,  $k$  je prvek signálu a  $N$  je délka signálu.

### **Průměrná frekvence (MNF)**

Z frekvenční oblasti je získáno spektrum pomocí Fourierovy transformace. Z amplitudové složky frekvenčního spektra je počítán průměr. Rovnice 3.6 uvádí vzorec pro výpočet MNF.

$$MNF = \frac{\sum_{k=1}^N f_k P_k}{\sum_{k=1}^N P_k} \quad (3.6)$$

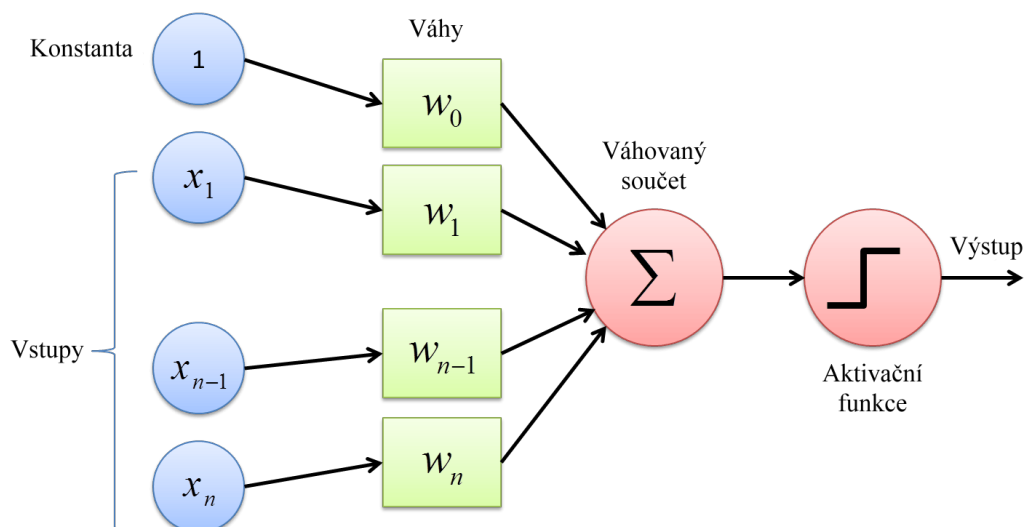
kde  $P_j$  je hodnota výkonového spektra EMG signálu na frekvenci  $f_j$  a  $N$  je polovina vzorkovací frekvence.

## **3.6 Metody umělé inteligence**

Dalším přístupem je využití vícevrstvé struktury algoritmů – neuronové sítě. Síť je tvořena velkým množstvím jednotlivých neuronů uspořádaných ve vrstvách. Každá vrstva má určitý počet neuronů a každý neuron má své parametry. Pro názornost je na obrázku 3.2 zobrazena nejjednodušší síť obsahující jeden neuron (perceptron) [31].


Model perceptronu obsahuje „n“ vstupů a stejný počet vah. Každý vstup je násoben příslušnou vahou, poté přiveden do sčítače, čímž vzniká váhovaný součet, k němuž je přičtena prahová hodnota. Výsledná hodnota následně vstupuje do aktivizační funkce. Výstup aktivizační funkce je shodný s výstupem sítě. V procesu učení

dochází v každé iteraci k výpočtu chyby dle předem stanovené chybové funkce. Podle této chyby jsou následně upraveny váhy. Dalšími nastavitelnými parametry sítě jsou rychlost učení a počet epoch [31].



Obr. 3.2: Proces učení perceptronu [35]

V závislosti na počtu skrytých vrstev se jedná o metody „mělkého“ (z angl. shallow) a „hlubokého“ učení (z angl. deep learning). Skryté vrstvy je chápány jako vrstvy mezi vstupní a výstupní vrstvou neuronové sítě. Příklad neuronové sítě se dvěma skrytými vrstvami znázorňuje obrázek 3.3. Jedná se o moderní metody, které lze považovat za součást strojového učení. Jelikož součástí neuronové sítě je často i předzpracování dat, vstup sítě nevyžaduje extrakci příznaků, nýbrž vstupem jsou surové signály [30][31].



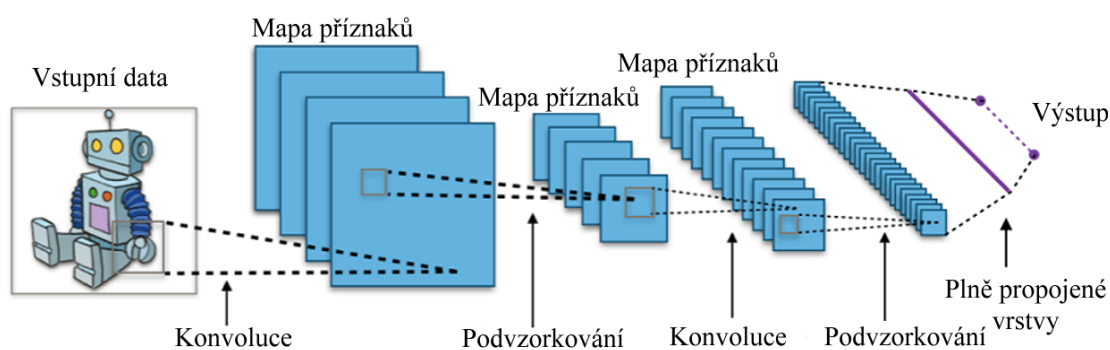
Obr. 3.3: Příklad struktury neuronové sítě [35]

Hluboké učení je založeno na modelech skládajících se z více vrstev. Model komplexně vystihuje vztahy mezi daty. Velmi populárními se staly konvoluční a rekurentní neuronové sítě [37].



## 3.7 Konvoluční neuronové sítě


Konvoluční sítě (CNN) tvoří jednu z hlavních kategorií umělé inteligence, přičemž široké uplatnění nachází především v oblasti zpracování obrazů, například pro detekci a rozpoznávání objektů. CNN jsou složeny z několika konvolučních, sdružujících a spojujících vrstev. Pro názornost je princip popsán na obrazových datech. Příklad konvoluční sítě je uveden na obrázku 3.4 [37][39].



Obr. 3.4: Konvoluční neuronová síť [38]

### Konvoluční vrstva

V prvním kroku dochází ke konvoluci vstupu s filtrem, čímž jsou extrahovány příznaky ze vstupních dat. Vstupem konvoluční vrstvy je tedy matice vstupních dat a maska (tzv. kernel). Výpočet jednoho prvku s velikostí kernelu tři je znázorněn na obrázku 3.5. Výstup konvoluční vrstvy je nazýván jako příznaková mapa. Využitím rozdílných filtrů dochází k různým operacím, například rozmazání dat či k detekci hran v obraze [39].




Obr. 3.5: Konvoluce vstupu s filtrem

Při konvoluci jsou důležité dva další parametry - střída (z angl. „stride“) a polstrování (z angl. „padding“). „Stride“ je počet pixelů, o který je filtr posunut v ná-

sledujícím kroku, zatímco „padding“ je doplnění okrajů nulami [39].

### Aktivační funkce


Výstup konvoluční vrstvy vstupuje do aktivační funkce, jež může mít různý průběh. V CNN je nejčastěji využívána aktivační funkce ReLU, jejíž průběh je na obrázku 3.6 [38][39].



Obr. 3.6: Aktivační funkce ReLU [38]

### „Pooling“

Další důležitou vrstvou je „pooling“, jež realizuje podvzorkování dat, čímž dochází k postupnému snižování velikosti vstupních dat. Tato vrstva snižuje požadavky na paměť - data jsou menší a zároveň dochází k méně výpočtům. Sdružování dat lze realizovat různými způsoby, jako například průměrování, sumací či výběrem maximální hodnoty v okně. Výběr maximální hodnoty (tzv. „max-pooling“) v okně o velikosti 2x2 a střídou 2 je znázorněn na obrázku 3.7. Z okna je vždy ponechán pouze prvek s nejvyšší hodnotou.



Obr. 3.7: „Pooling“ vrstva

### Plně propojená vrstva

Neuron v plně propojené vrstvě je spojen se všemi výstupy neuronů vrstvy předchozí. Plně propojená vrstva následuje za sérií konvolučních a „pooling“ vrstev. Transformuje výstupy z předchozí vrstvy do jediného vektoru.

### 3.8 Konvoluční sítě pro zpracování 1D signálů

Konvoluční sítě jsou velmi využívaným přístupem především pro zpracování dvou-rozměrných dat. Avšak 1D konvoluční neuronové sítě (CNN) se v poslední době staly nejmodernějším přístupem pro zpracování signálů [40][41].


Existují dva základní přístupy pro zpracování jednorozměrných dat s využitím CNN. První technika je založena na konverzi dat na 2D signál - obraz. Druhou možností je zpracování pouze 1D signálu bez konverze [40][41].

Hlavní rozdíl je v konvoluci, která je při zpracování bez konverze realizována jako jednorozměrná, což má za následek menší výpočetní náročnost. Vstupem do konvoluční sítě je surový signál, což znamená, že není potřeba žádné předzpracování dat. Taktéž výstupem jsou přímo segmentovaná data a není potřeba je nijak upravovat. Eliminací preprocessingu a postprocessingu je ušetřen čas, který je při real-time zpracování velmi cenný. Při zpracování 1D dat v porovnání s daty 2D, síť vyžaduje menší počet trénovacích (anotovaných) dat, což je další velkou výhodou při realizaci. 1D signály jsou také méně náročné na paměť systému [40][41].

V praxi jsou 1D CNN aplikovány například při zpracování EKG pro detekci různých arytmií, pro automatickou detekci spánku z EEG, klasifikaci pohybu očí či pro zvukové klasifikace [40][41].

## 4 REAKČNÍ DOBA

Reakční doba je časový úsek od počátku podnětu do odpovědi vyšetřovaného. Jedná se o dobu, kterou organismus potřebuje ke zpracování a vyhodnocení daného podnětu. Podnět je smyslovým orgánem detekován, následně je pomocí nervových drah veden do příslušné části mozku, kde dochází ke zpracování. Dalším krokem je vyhodnocení podnětu a případné rozhodování například o provedení či neprovedení úkonu, typu úkonu apod. Následně je vyslána informace pomocí motorických neuronů do svalové skupiny, kde dochází k aktivaci svalu. Podnět může být různého charakteru, v praxi se nejčastěji využívá podnět zvukový či vizuální. Celý proces od vzniku podnětu po realizaci odpovědi je znázorněn na obrázku 4.1 [42][43].




Obr. 4.1: Princip vzniku odpovědi na podnět [44]

Reakční dobu lze rozdělit do následujících úseků (viz. obrázek 4.2):

**optická reakce** - doba nutná k registraci podnětu v zorném poli a následné zaostření na daný objekt

**psychická reakce** - doba od zafixování podnětu do počátku aktivace svalu (zpracování podnětu centrální nervovou soustavou)

**svalová reakce** - doba, kdy dochází k pohybu daného svalu [45]




Obr. 4.2: Rozdělení reakční doby [43]

## 4.1 Faktory ovlivňující reakční dobu

Reakční doba jednotlivce je ovlivněna mnoha faktory. Zásadní vliv na reakční dobu má druh použitého testu, charakter podnětu, dále psychický či fyzický stav vyšetřovaného. Jedním z nejvíce ovlivňujících faktorů je varianta testu, která byla při měření využita. Existují tři různé varianty testů reakční doby, které se liší vazbou podnětu s odpovědí.

Nejzákladnější variantou je jednoduchý test, kde vyšetřovaný rozhoduje pouze o přítomnosti jednoho podnětu. Požadovaná odpověď na stimul je vždy stejná. Příkladem může být stisknutí tlačítka po zobrazení obrázku na displeji. Druhým typem testu je test rozpoznávací. Pacient reaguje na jeden typ podnětů a další typy ignoruje. Příkladem může být rozpoznávání kruhových objektů od hranatých. Posledním a zároveň nejtěžším testem je test výběrový, který zahrnuje více různých podnětů a více různých odpovědí. Může se jednat například o stisknutí určité klávesy po zobrazení určitého obrázku. Podle studie, kterou v roce 1952 zveřejnil Hick, je reakční doba úměrná logaritmu počtu podnětů [46][47].

Reakční dobu zásadně ovlivňuje typ daného stimulu. Odezva na vizuální stimul je mnohem delší než na stimul zvukový. U zdravých mladých lidí doba reakce na zvukový podnět trvá přibližně 140–160 ms, zatímco odezva na vizuální podnět leží v rozmezí 180–200 ms. Reakce na dotek je nejrychlejší, avšak její doba závisí na místě doteku. Ovšem v časech potřebných pro odezvu se jednotlivé studie výrazně liší. Například ze studie [50] vychází, že průměrná reakční doba na vizuální stimul je 331 ms, zatímco na zvukový podnět 284 ms [47][48][49].



Obr. 4.3: Závislost reakční doby na intenzitě podnětu a napětí svalu [47]

U stimulů také závisí na použitých parametrech, jako jsou například délka trvání či intenzita stimulu. Vizuální a zvukové podněty, které trvají déle, vyvolávají rychlejší reakci. Reakční doba je kratší, čím vyšší intenzita podnětu je. Například reakční doba na slabé světlo je delší než reakční doba na světlo o vyšší intenzitě.

Reakční doba se zkracuje pouze do určité intenzity podnětu, poté reakční čas zůstává téměř konstantní. Závislost vyjadřuje je vyjádřena na obrázku 4.3 A [47].

Při měření reakční doby je důležité, aby se vyšetřovaný maximálně soustředil. Pacientovo soustředění je úzce spojeno s jeho motivací. Míra kontrakce svalu před stimulem také ovlivňuje výslednou dobu reakce. Pokud je sval příliš relaxovaný, nebo naopak příliš zatnutý, reakční doba se prodlužuje. Tento vztah simuluje obrázek 4.3 B [47].

Dalším parametrem ovlivňující dobu reakce je pohlaví. Bylo zjištěno, že ženy mají delší reakční čas v porovnání s muži. Stisknutí tlačítka v reakci na světlo ženám trvalo průměrně 260 ms, mužům pouze 220 ms. Na zvukový podnět odezva žen trvala 200 ms, u mužů 190 ms. Další studie také prokázala rozdílné reakční doby na zvukový podnět. U žen bylo dosaženo odpovědi po 242 ms, zatímco u mužů po 227 ms. Studie [44] tento rozdíl mezi pohlavím také utvrzuje [46][47].

Se zvyšujícím se věkem či u pacientů s kognitivními poruchami dochází ke zpomalení reakcí. Pokles kognitivních funkcí se však může změnit při onemocnění. Ke zpomalení reakcí dochází dále například po požití omamných látek, při hladovění, únavě či vyrušování subjektu při měření. Na reakční dobu může mít také vliv měření dominantní či nedominantní končetiny [46][47][49].

Měření lze ovlivnit také pravidelností opakování, ať už jednoho či více podnětů. Se zvyšující se pravidelností vyšetřovaný podnět očekává v určitou chvíli, čímž se doba reakce výrazně zkracuje [47][48].

Uvedené reakční doby se v jednotlivých výzkumech mezi sebou výrazně liší, což může být způsobeno různými faktory, které byly zmíněny výše, ale také použitým hardwarovým a softwarovým vybavením.

## 4.2 Měření reakční doby

Reakční dobu lze měřit různými způsoby. Nejčastěji se jedná o záznam pohybu končetin. Avšak reakční dobu lze zaznamenávat z pohybu celého těla, nebo naopak pouze z pohybu očí či změny průměru zornice [51].

Při snímání pohybu končetiny je možné využít různých typů záznamu. Nejjednodušším řešením je stisknutí klávesy či jiného tlačítka. Možnost snímat pohyb umožňuje také gyroskop. U obou technik měření se jedná o velmi přesné měření reakční doby [51].

Dalším využívaným způsobem je snímání akcelerometrem. Z naměřeného zrychlení je stanovena reakční doba. Pro určení doby se využívá prahových metod. Čas

reakce odpovídá času, kdy zrychlení složky  $x$  překročí předem zvolený práh. Při porovnání reakčních časů získaných stisknutím tlačítka a ze záznamu akcelerometru se časy liší. Z dat akcelerometru jsou absolutní hodnoty reakčních časů delší, avšak rozdíly zůstávají konstantní [46].

Pohyb končetiny či pohyb těla lze stanovit z elektromyografického signálu. Signál se mění podle prováděných pohybů vyšetřovaného. Principy vzniku EMG signálu jsou popsány v kapitole 1.

### 4.3 Stanovení reakční doby z EMG signálu

Reakční doba je ovlivněna nejen faktory zmíněnými v kapitole 4.1, ale také použitým algoritmem pro odhad reakční doby. Literatura zabývající se reakční dobou je rozsáhlá, avšak neexistuje žádný standard pro její přesné stanovení [42].

Jedna z nejčastějších skupin metod využívá prahování EMG signálu. Prahová hodnota je klíčovým parametrem pro odlišení EMG bez aktivity (šumu) od kontrakcí. Úsek, ve kterém pacient začal reagovat, je v místě překročení prahové hodnoty. Nastavení hodnoty prahu není jednoduché, a tak se reakční doby v různé literatuře liší. Metoda musí být dost citlivá na to, aby zachytila výchyly ve velmi zašuměných signálech, avšak pouze do takové míry, že méně zašuměné signály nebudou detekovat falešné odezvy [42][54].

#### Metody založené na určení prahu

Práh je často určen na základě střední hodnoty či směrodatné odchylky základní linie. Za základní linii lze považovat klidový EMG signál, nebo signál v čase okolo výskytu podnětu. Hodnota prahu bývá nastavena na 1,4násobek směrodatné odchylky, nebo na hodnoty vyšší [42][52][53].

Prahová hodnotu lze stanovit z filtrovaného signálu např. filtrem typu dolní propust. Práh je trojnásobkem směrodatné odchylky z okna trvajícího 50 ms. Pro eliminaci krátkých vrcholů, které jsou pouze falešné odezvy, lze použít omezení, že nadprahový impulz musí trvat minimálně 25 milisekund [42][54].

Další možností určení prahové hodnoty je na základě maximální hodnoty vrcholu. Práh je nastaven na pět procent maxima vrcholu. Tato metoda ovšem detekuje mnoho falešných píků [42].

Komplikovanější metodou pro stanovení prahu je využití rekurzivní metody. Algoritmus v prvním kroku nalezne jasnou odpověď na podnět. Následně zpětně vyhledá počátek vrcholu, který je stanoven při překročení jedné směrodatné odchylky od základní linie [42].

## Metody založené na extrapolaci dat

Další metoda pro určení reakční doby je založena na extrapolaci dat. Prvně je stanoveno maximum vrcholu, následně jsou vyhledány body, kde hodnoty dosáhnou 25 % a 75 % maxima. V dalším kroku je přes nalezené body proložena křivka. Bod, ve kterém tato křivka překročí základní linii, je označen jako počátek reakce. Metoda extrapolace není příliš citlivá na vyhlazení signálu [42].

## Metody založené na statistickém rozhodování

Poslední skupina metod pro stanovení reakční doby je založena na statisticky správném rozhodnutí. Jedná se o metody předpokládající určité vlastnosti signálů, odhady parametrů dle rozložení signálu. Ze signálu EMG lze extrahovat parametry v časové, časově-frekvenční či frekvenční oblasti. Příznaky jsou vybírány tak, aby co nejlépe vystihovaly rozdíly v signálu (klidový signál vs. signál při pohybu). Změna těchto parametrů stanovuje začátek svalové aktivity. Vybrané extrahované příznaky pro detekci aktivity v EMG signálu jsou uvedeny v kapitole 3.5 [42].

Výsledná hodnota příznaku reprezentuje daný úsek signálu. Kombinací příznaků lze následně aktuální úsek zařadit do příslušné kategorie klid vs. aktivita svalu. Pro přiřazení je často využíváno metod strojového učení [55], jak je již popsáno v kapitole 3.5 [42].

## 4.4 Využití reakční doby

Reakční doba je využívána v mnoha oborech, například v medicíně, sportovním odvětví či při dopravních analýzách. Měření lze využít pro hodnocení únavy či míry soustředěnosti člověka. Reakční doba člověka může být také ukazatelem požití alkoholu či jiných omamných látek [46].

Doba reakce je jeden z nejdůležitějších aspektů využívajících se při analýze chování řidičů. Rychlými reakcemi řidiče lze předejít spoustě dopravních nehod, naopak při zpomalených reakcích se riziko dopravní nehody zvyšuje [53].

Reakční doba se dále využívá na neurologických, psychologických či psychiatrických odděleních. Při snížené kognitivní schopnosti se schopnost rychlé reakce snižuje. Kognitivní pokles je typický proces stárnutí. Ovšem kognitivní poruchy jsou přítomny také u pacientů trpících Alzheimerovou chorobou či demencí. Včasné odhalení poklesu kognitivní funkce umožňuje dřívejší zahájení léčby daného onemocnění [46].



## 5 BITALINO

Pro snímání EMG signálu je v práci využita platforma BITalino. Jedná se o hardware určený pro vzdělávání, vytváření prototypů či výzkum v biomedicínském inženýrství [56].

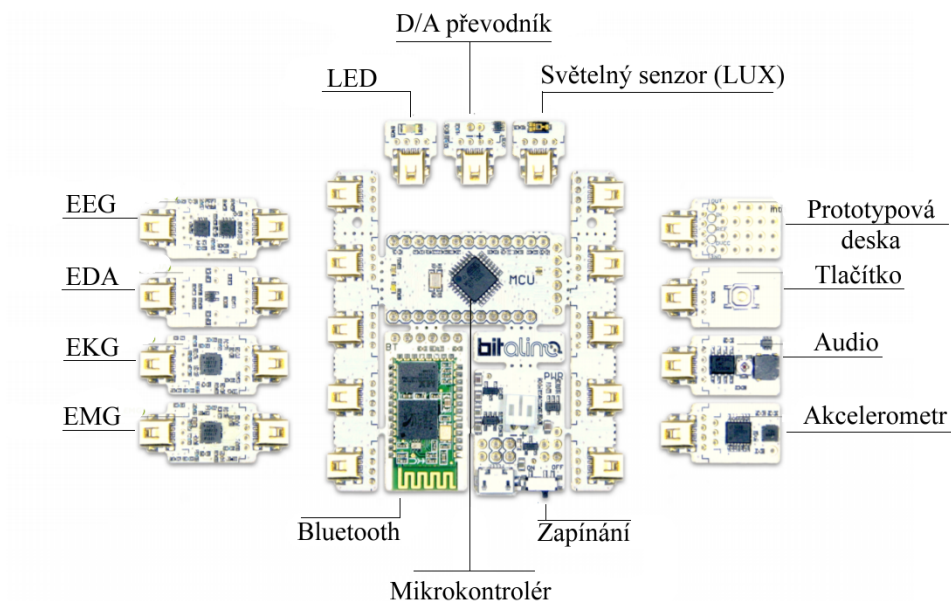
### 5.1 Technická specifikace BITalina

Cílem portugalské firmy BITalino je poskytnout levný, ale zároveň funkční systém pro snímání biologických signálů. Existují tři základní produkční verze, podle defaultně obsažených komponent. V nejzákladnější typu „Board Kit“ jsou obsaženy všechny základní senzory v jedné desce. Druhou verzí je „Plugged Kit“, kde bloky pro snímání biologických signálů tvoří samostatné komponenty a uživatel si může BITalino částečně přizpůsobit. Třetí varianta „Freestyle Kit“ obsahuje pouze jednotlivé bloky, čímž je dosaženo větší možnosti přizpůsobení. Zařízení BITalino umožňuje záznam elektrické aktivity myokardu (EKG), kosterních svalů (EMG), mozku (EEG), žaludku (EGG), očních pohybů (EOG), dále je také možné snímat elektrodermální aktivitu (EDA), zrychlení (ACC), respiraci, teplotu či osvětlení (LUX) [56].

Tab. 5.1: Přehled parametrů BITalina [56]

Parametr	Možnosti BITalina
Vzorkovací frekvence	1–1000 Hz
Analogové porty	4 vstupní (10-bit), 2 vstupní (6-bit), 1 pomocný vstupní (baterie) + 1 výstupní (8-bit)
Digitální porty	2 vstupní (1-bit) + 2 výstupní (1-bit)
Komunikace	Bluetooth 2.0
Dosah	2 do 10 m
Senzory	EMG, EKG, EEG, EDA, ACC, LUX
Upozornění	Světelné (LED) nebo akustické
Rozměry	100 x 65 x 6 mm
Spotřeba	65 mA

V práci je využito BITalino typu „Plugged Kit“. Funkční bloky jsou znázorněny na obrázku 5.1. K základní desce je zapojen modul sloužící pro snímání EMG signálu. Přehled jednotlivých parametrů BITalina, jež byly převzaty z technické dokumentace, shrnuje tabulka 5.1 [56].



Obr. 5.1: Funkční bloky BITalina typu „Plugged“ [56]

## 5.2 EMG modul

V práci je použit modul EMG, jehož vlastnosti jsou shrnuty v tabulce 5.2.

Tab. 5.2: Parametry EMG modulu [56]

Parametr	Hodnoty pro EMG modul
Zesílení	1009
Rozsah	$\pm 1.64$ mV (při VCC = 3,3 V)
Šířka pásma	25-480 Hz
Spotřeba	0,17 mA
Vstupní rozsah napětí	2,0-3,5 V
Vstupní impedance	7,5 G $\Omega$
CMRR	86 dB

Celý systém je napájen baterií o kapacitě 700 mAh, kterou lze dobít přes USB kabel. Přenos informací z BITalina do zařízení (např. do PC) je realizován přes Bluetooth 2.0, což je výhodné především pro pacientovu bezpečnost. Bluetooth má dosah až 10 metrů, tudíž pacient není příliš omezován při svých pohybech. Přenosová rychlost implementovaného Bluetooth je 115,2 megabitů za sekundu, což je srovnatelné s konkurenčním zařízením Arduino [56][57].

## 6 IMPLEMENTACE HRY

Pro zvýšení motivace pacienta byla implementována závodní hra ovladatelná svalovou aktivitou. Úkolem probanda je ovládat hru kontrakcí a dilatací svalu, a tak co nejrychleji reagovat na generované podněty. Cílem je zároveň urazit co největší vzdálenost bez střetu s protijedoucími vozidly.

Základ hry byl převzat ze zdrojového kódu, který je volně k dispozici na úložišti GitHub [58]. Celá hra však byla pozměněna tak, aby odpovídala požadavkům myofeedbacku. Zdrojový kód byl optimalizován, čímž byla dosažena nižší výpočetní náročnost hry. Následně bylo upraveno uživatelské rozhraní a byly implementovány jednotlivé objekty, jako například vozidlo záchranné služby, semafor či pokyny pro hráče.

### 6.1 Menu

Po spuštění hry je probandovi prvně zobrazeno hlavní menu hry, které je vyobrazeno na obrázku 6.1. Pro přehlednost je text fokusovaného tlačítka červený, viz. obrázek 6.1 vpravo.

Jestliže hráč hru zná, případně jsou hráči veškerá pravidla vysvětlena, může kliknutím na položku „Hrát“ spustit hru, čímž současně dojde k začátku zaznamenávání EMG aktivity. Pro případ, že proband ovládání či pravidla hry nezná, je zde nápověda, která se zobrazí po kliknutí na příslušnou položku v menu. Své nejlepší výsledky může proband zobrazit v sekci „Rekord“. Záznamy je možné odstranit kliknutím na položku „Smazat záznamy“, přičemž se program opětovně zeptá, zda uživatel chce opravdu záznam odstranit. Hra je ukončena kliknutím na tlačítko „Konec“, stisknutím „ESC“ na klávesnici, případně zavřením okna.



Obr. 6.1: Menu hry

## Nastavení

V menu, konkrétně v sekci „Nastavení“, má uživatel možnost výběru metody, která bude ve hře využita pro zpracování EMG signálu. Jak lze vidět na obrázku 6.2, jednotlivé implementované metody jsou reprezentovány „checkboxem“. Současně může být vybrána pouze jedna z metod, což je ošetřeno tak, že po výběru jiné metody je předchozí metoda nahrazena novou. Vybraná metoda je uložena v globální paměti.



Obr. 6.2: Nastavení - výběr metody

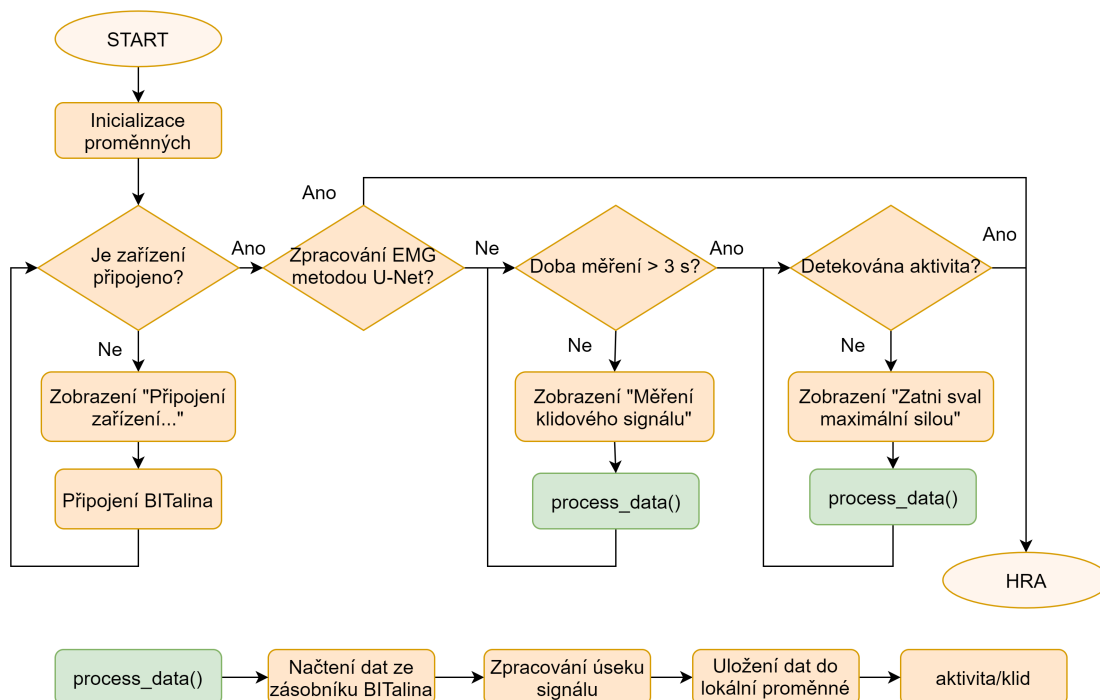
## 6.2 Průběh hry

Po kliknutí na tlačítko „Hrát“ je zobrazena obrazovka s pozadím hry. V popředí jsou uvedeny instrukce pro hráče. Nejprve je realizováno připojení BITalina (obrázek 6.3 vlevo). Při využití metody U-Net hra začíná ihned po připojení BITalina. V případě, že není nastaveno zpracování signálu EMG metodou U-Net, následuje snímání klidového EMG signálu po dobu tří sekund, o čemž je hráč informován instrukcí, jež je zobrazena na obrázku 6.3 uprostřed. Následně je zobrazen další pokyn (obrázek 6.3 vpravo), což je důležité zejména při použití metody SVM pro normalizaci dat.




Obr. 6.3: Pokyny pro hráče

Algoritmus, jež je aplikován před samotným spuštěním hry, je znázorněn diagramem na obrázku 6.4 nahoře, zatímco struktura funkce zajišťující zpracování dat je v tomto obrázku v dolní části.



Obr. 6.4: Vývojový diagram inicializace hry


Hra vždy začíná ve stavu, kdy hráč čeká na změnu barvy semaforu, konkrétně na zelenou barvu. Současně je zobrazena instrukce, aby hráč vyčkal na změnu barvy semaforu, viz. obrázek 6.5 vlevo. Se změnou barvy semaforu na zelenou se změní i instrukce (obrázek 6.5 vpravo) a je očekávána reakce probanda. Jakmile je detekována aktivita svalu, hra začíná.



Obr. 6.5: Semafor se zobrazenými pokyny



Úkolem probanda je ovládat hru kontrakcí a dilatací svalu, a co nejrychleji reagovat na generované podněty. Vývoj hry je nastíněn na obrázku 6.6. V průběhu hry je v náhodném čase měněna barva semaforu, na kterou hráč musí zareagovat do jedné sekundy pohybem dolní končetiny (sešlápnutí pedálu), jinak hra končí. Zároveň se hráč musí vyhýbat protijedoucím vozidlům. V případě, že se na silnici objeví vozidlo záchranné služby je třeba zareagovat stejně, jako při změně barvy semaforu, tedy sešlápnutím pedálu. V průběhu hry se protijedoucí vozidla pohybují čím dál rychleji, což zvyšuje obtížnost hry. Cílem hry je dosáhnout co nejvyššího skóre. Čím delší vzdálenost ve hře hráč urazí, tím vyšší skóre získá. V případě, že hráč reaguje na podněty dostatečně rychle, získává „bonusy“, což navýší celkové skóre. S ujetou vzdáleností ubývá paliva, které hráč doplní tak, že střetne ikonu reprezentující benzín.

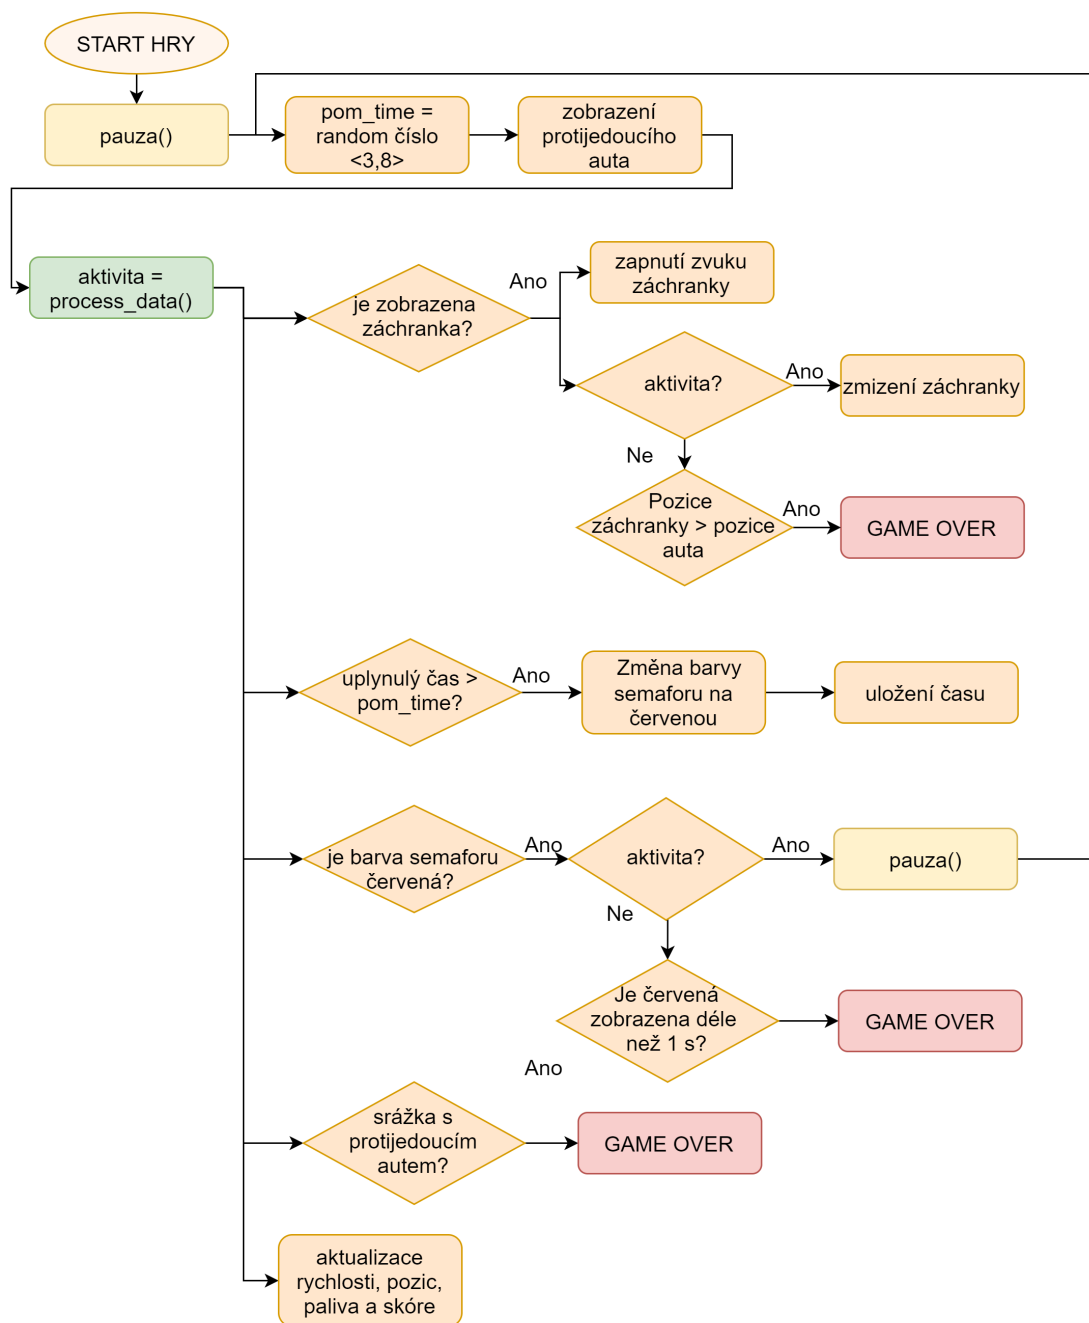


Obr. 6.6: Průběh hry

(A) Zobrazení protijedoucího vozidla, (B) Zobrazení vozu záchranné služby, (C) Získání bonusových bodů za rychlou reakci, (D) Konec hry způsobený pomalou reakcí

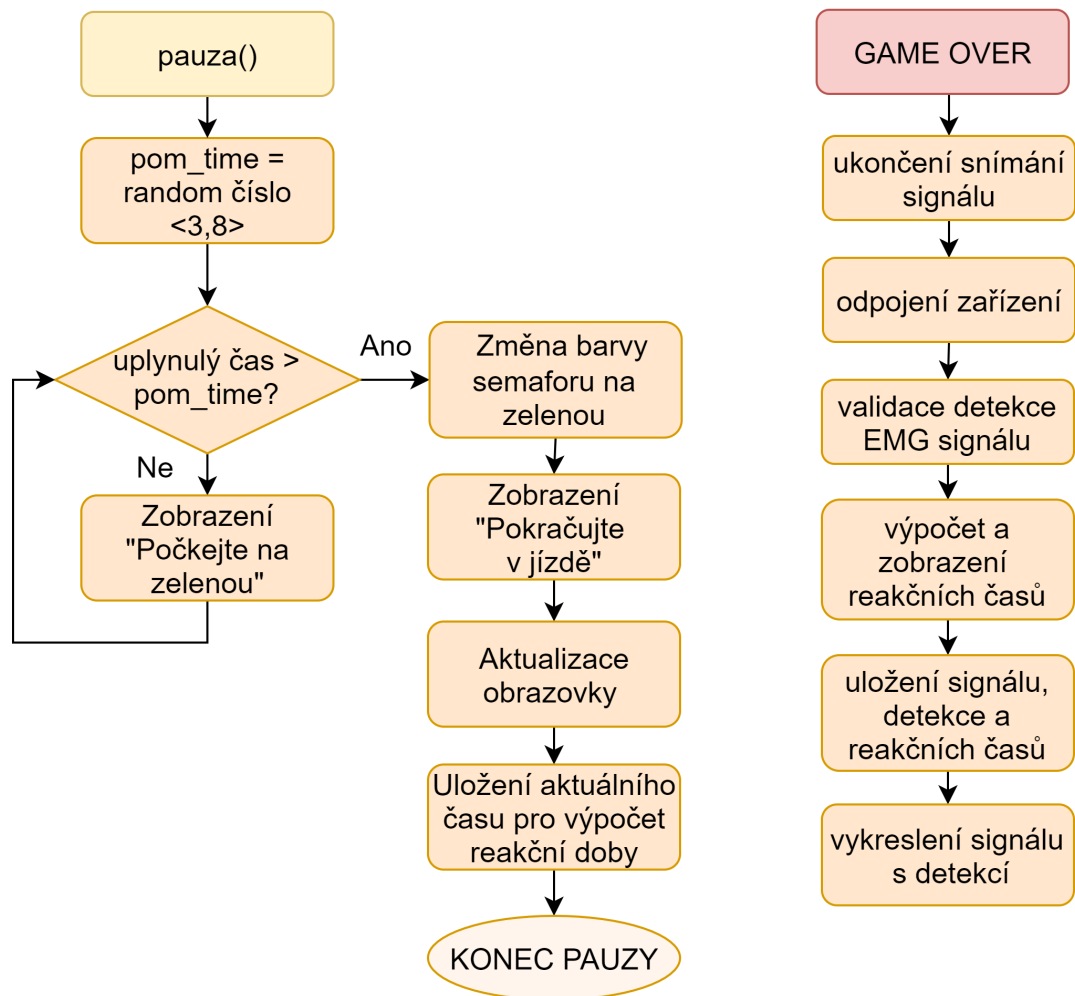
Po celou dobu hry je snímán EMG signál, který je z BITalina načítán v oknech o velikosti 100 ms a následně v tomto okně zpracován. Příslušná odpověď je hráči vizualizována příslušnou změnou stavu hry.

Hra je ukončena v případě, že hráč nezareaguje (nesešlápne pedál) do sekundy od zobrazení objektu ve hře, nebo v případě srážky s protijedoucím vozidlem. Poslední variantou ukončení hry je, že hráči dojde palivo (benzín), což je znázorněno červeným obdélníkem pod názvem „FUEL“, jež je na obrazovce umístěn v levém horním rohu.



Obr. 6.7: Vývojový diagram průběhu hry

Po skončení hry (prohře) jsou zobrazeny výsledky reakčních dob - průměrná a nejlepší. Současně je do .csv souboru uložen nasnímaný (surový) EMG signál a příslušné binární hodnoty odpovídající klasifikaci, zda byl vzorek signálu označen jako aktivita svalu či klid (hodnoty 0 a 1). Uloženy jsou také jednotlivé reakční časy a informace, zda se jednalo o reakci na změnu barvy semaforu či o reakci na vůz záchranné služby. Vývojový diagram celé hry je na obrázku 6.7, algoritmus probíhající v momentě, kdy je automobil zastaven je znázorněn obrázkem 6.8 vlevo, zatímco funkce, jež jsou uplatněny po skončení hry jsou reprezentovány diagramem na tomto obrázku vpravo.



Obr. 6.8: Vývojový diagram - pauza a ukončení hry

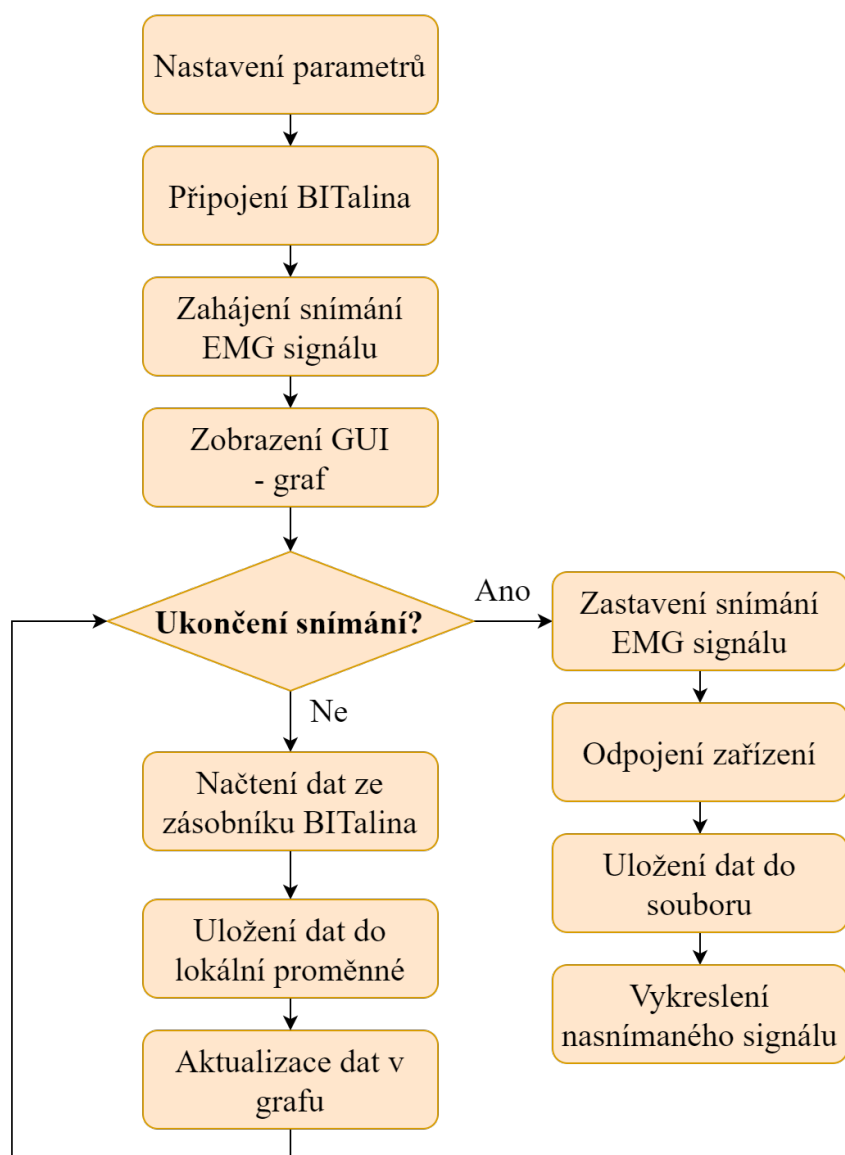


## 7 ZPRACOVÁNÍ SIGNÁLU

Zařízení BITalino zaznamená signál, který je následně přenesen pomocí Bluetooth do počítače, kde je dále zpracováván.

### 7.1 Připojení BITalina a zobrazení signálu

Připojení BITalina je realizováno knihovnou „bitalino“ v Pythonu. Schéma připojení zařízení, snímání signálu a vykreslení dat je znázorněno na obrázku 7.1.




Obr. 7.1: Vývojový diagram snímání signálu BITalinem

Vstupním parametrem je vzorkovací frekvence, která je nastavena na maximální hodnotu, kterou BITalino umožňuje – 1000 Hz. Druhým parametrem je velikost okna, ve kterém jsou vzorky načteny. Vzorky signálu jsou ukládány v zásobníku BITalina a po následném načtení počítačem je tento zásobník uvolněn pro nové vzorky. Okno musí být dlouhé natolik, aby mělo výpovědní hodnotu. Zároveň nesmí být příliš dlouhé kvůli odezvě. Bylo zvoleno okno o velikosti 100 ms. Uživatel si může také zvolit dobu snímání.

Zařízení je připojeno na základě unikátní MAC adresy daného zařízení, což je vstupním parametrem funkce zajišťující připojení zařízení BITalino. Funkcí „start“ je zahájeno snímání EMG signálu, zároveň je uložen čas počátku snímání v nanosekundách, což slouží pro následný výpočet reakční doby.

Pro ověření správného zapojení či pro kontrolu funkčnosti snímání EMG signálu má uživatel možnost signál vykreslovat v téměř reálném čase. Po zahájení snímání signálu je zobrazeno okno, ve kterém je vizualizován snímaný signál. Graf je aktualizován po každém načtení vzorků ze zásobníku BITalina do počítače. Vytvořené GUI je zobrazeno na obrázku 7.2 vlevo. Po uplynutí nastavené doby, či jiné ukončovací podmínky, je snímání EMG zastaveno funkcí „stop“, současně je ukončeno vykreslování dat a zařízení je odpojeno, což je realizováno funkcí „close“. Data jsou uložena do souboru ve formátu .csv. Každý soubor má charakteristický název, který je dán aktuálním datem a časem. Celý záznam EMG signálu je zobrazen uživateli (obrázek 7.2 vpravo).

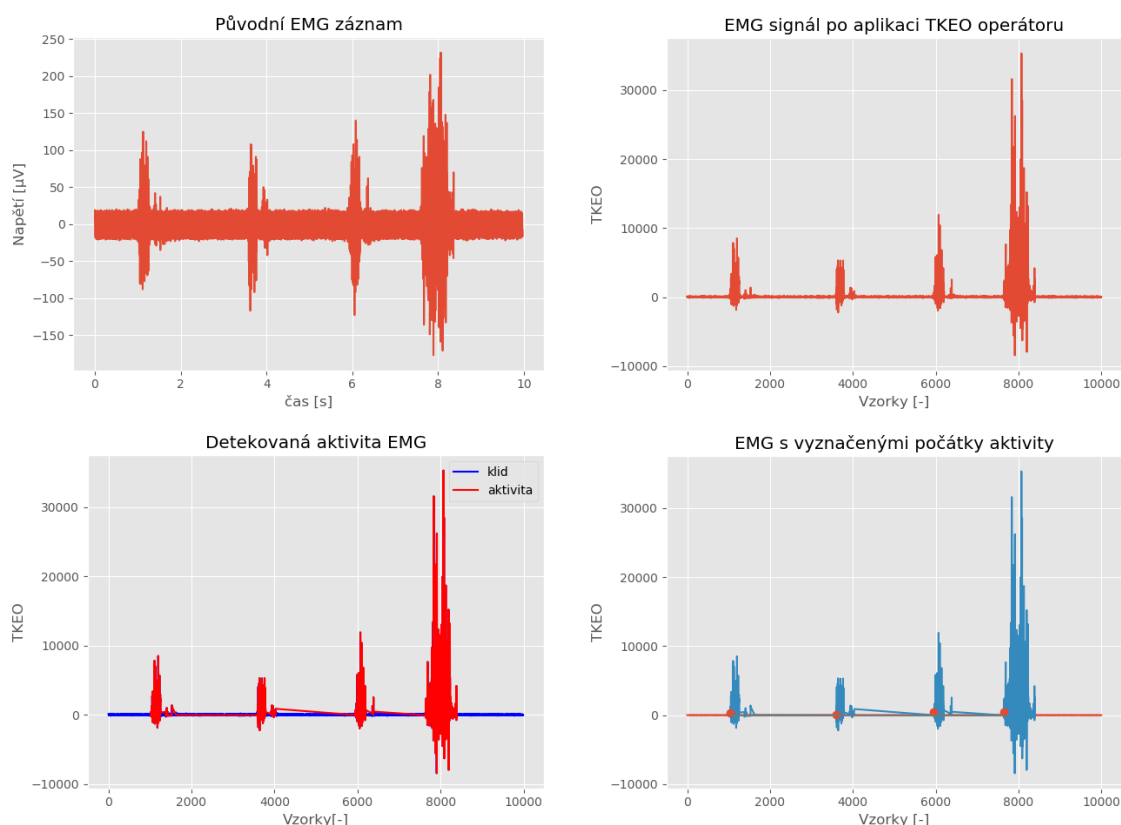


Obr. 7.2: Vizualizace snímaného EMG signálu

Pro detekci aktivity byly použity tři různé algoritmy – neuronová síť U-Net, metoda strojového učení Support Vector Machine (SVM) a prahování signálu upraveného TKEO operátorem. Jednotlivé metody jsou popsány v následujících podkapitolách. Porovnání dosažených výsledků těchto metod je obsaženo v kapitole 8.1.

## 7.2 Zpracování signálu – TKEO operátor

Nejjednodušší implementovanou metodou je metoda založená na prahování signálu, jež je upraven nelineárním operátorem TKEO. Princip této metody je popsán v kapitole 3.2. Na signál je aplikován TKEO operátor, čímž je zvýšena úroveň signálu a zároveň je zvýrazněn užitečný signál. Pro stanovení počátků svalové aktivity je využito prahování. Práh je stanoven v závislosti na směrodatné odchylce signálu po aplikaci TKEO operátoru. Konkrétně byla zvolena hodnota pětinasobku směrodatné odchylky.




Obr. 7.3: Aplikace metody TKEO

## 7.3 Zpracování signálu – metoda SVM

Support vector machines (SVM) je metoda strojového učení, jejíž princip je popsán v kapitole 3.5.

Vstupem jsou příznaky extrahované z aktuálního úseku signálu. Před extrakcí těchto příznaků jsou data předzpracována. V prvním kroku je signál pro větší výnosnost signálu rektifikován - na signál je aplikována absolutní hodnota. Následně

jsou data normalizována. Z takto předzpracovaných dat jsou extrahovány příznaky, které vystihují daný úsek signálu. Jednotlivé příznaky, jež byly využity pro klasifikaci jsou uvedeny v kapitole 3.5. Nejprve je potřeba naučit model (najít optimální křivku rozdělující prostor příznaků), k čemuž je nutné mít označená data. Klasifikace dat je pak už velmi rychlá. Příklad klasifikovaného signálu zobrazuje obrázek 7.4.




Obr. 7.4: Klasifikovaný signál metodou SVM

## 7.4 Zpracování signálu – konvoluční neuronová síť

Metody umělé inteligence jsou velmi perspektivními přístupy, jež se využívají především při zpracování dvourozměrných signálů. Základní poznatky o neuronových sítích jsou popsány v kapitole 3.6. Jak je již v teorii popsáno, pro segmentaci jsou vhodné konvoluční neuronové sítě. Vybavování již naučené sítě je velmi rychlé, což je při myofeedbacku velmi důležitý faktor. Pro klasifikaci signálu byla navržena a naprogramována konvoluční neuronová síť se strukturou U-Net. Síť klasifikuje jednotlivé vzorky EMG signálu do dvou kategorií – klidové úseky a úseky reprezentující svalovou aktivitu


## Struktura neuronové sítě U-Net

U-Net je plně propojená konvoluční síť, jejíž struktura je znázorněna na obrázku 7.5. Skládá se ze dvou základních bloků – enkodéru a dekodéru. Příznakové mapy jsou v obrázku reprezentovány modrými obdélníky. Rozměry konkrétní příznakové mapy (její délka) je uvedena vždy u levého dolního rohu prvku. Hodnota nad obdélníkem udává počet kanálů. Jednotlivé operace jsou reprezentovány šipkami odpovídající legendě v obrázku [59].




Obr. 7.5: Struktura neuronové sítě U-Net [59]

Vstupem navržené neuronové sítě je surový signál, tudíž není potřeba žádné předzpracování signálu. V sestupné části (enkodéru) dochází ke snižování velikosti signálu. Konvolučními operacemi vznikají mapy příznaků. Následně jsou data normalizována funkcí „BatchNorm1d“ z knihovny „Pytorch“, čímž je zajištěno, že veškeré hodnoty leží v intervalu od 0 do 1. Tento krok značně urychluje fázi učení. Normalizovaná data jsou vstupem do aktivační funkce ReLU, jejíž průběh je zobrazen na obrázku 3.6. Operace „max pool“ realizuje podvzorkování dat. Z okna o velikosti dvou vzorků je vždy ponechán pouze vzorek s vyšší hodnotou, čímž dojde ke zkrácení signálu na polovinu. Tuto operaci znázorňuje obrázek 7.6.



Obr. 7.6: Operace „max pool“

Ve vzestupné části (dekodéru) je signál naopak nadvzorkován, což zajišťuje 1D transponovaný konvoluční operátor (v knihovně „Pytorch“ se jedná o funkci „ConvTranspose1d“). Základní princip funkce je znázorněn na obrázku 7.7, kde proměnné  $y$  označují prvky signálu, jež byl v dřívějších iteracích podvzorkován, „w“ jsou jednotlivé váhy a „x“ jsou prvky již nadvzorkovaného signálu. Výpočty jednotlivých prvků jsou uvedeny vždy pod konkrétním prvkem „x“. Z důvodu jednodušší interpretace obrázek 7.7 znázorňuje funkce s parametry: velikost filtru = 3, „stride“ = 1 a „padding“ = 0 (bez doplnění okrajů nulami). V navržené a implementované síti jsou však tyto parametry nastaveny následovně: velikost filtru = 2, „stride“ = 2 a „padding“ = 2. [59]




Obr. 7.7: Princip 1D transponovaného konvolučního operátoru

## Trénování sítě

Pro trénování sítě byla vytvořena databáze manuálně anotovaných signálů, jež byly označeny v místě zřejmé svalové aktivity.

## Manuální anotace dat

Anotace má formu přiřazení binární hodnoty každému vzorku signálu: 0 pro klidové EMG, 1 pro aktivitu. Příklad anotovaných signálů je znázorněn na obrázku 7.8. Databáze je rozdělena na trénovací a testovací množinu, přičemž trénovací množina obsahuje 544 signálů a testovací 42 signálů.



Obr. 7.8: Manuálně anotovaná data

## Optimalizační algoritmus

Při učení sítě je využit optimalizační algoritmus Adam, který je velmi efektivní. Adam je metoda, která využívá adaptivní rychlosti učení pro různé parametry. Kombinuje metodu RMSprop, jež využívá druhou mocninu gradientu pro změnu rychlosti učení, a metodu stochastického poklesu gradientu (SGD), která je založena na exponenciálním zapomínání gradientů z minulých iterací. Rychlost učení pro každou váhu jednotlivých neuronů je tedy přizpůsobena podle odhadu prvního (rovnice 7.1) a druhého momentu gradientu (rovnice 7.2). Výsledné váhy v následující iteraci jsou vypočítány rovnicí 7.3 [61][62].

$$\mathbf{m}^{(it+1)} = \beta_1 \mathbf{m}^{(it)} + (1 - \beta_1) g_{it} \quad (7.1)$$

kde  $\mathbf{m}$  je první moment - střední hodnota gradientu,  $it$  je iterace,  $\beta_1$  je parametr zapomínání gradientu a  $g$  je gradient.

$$\mathbf{v}^{(it+1)} = \beta_2 \mathbf{v}^{(it)} + (1 - \beta_2) g_{it}^2 \quad (7.2)$$

kde  $\mathbf{v}$  je druhý moment - nevycentrovaná variace gradientu,  $it$  je iterace,  $\beta_2$  je parametr zapomínání druhého momentu a  $g$  je gradient.

$$\mathbf{W}^{(it+1)} = \mathbf{W}^{(it)} - \mathbf{m}^{(it)} \frac{\mu}{\sqrt{\mathbf{v}^{(it)}} + \epsilon} \quad (7.3)$$

kde  $\mathbf{W}$  je váha neuronu  $\mu$  je krok učení,  $\epsilon$  je parametr vyhlazení,  $it$  je iterace,  $\mathbf{m}$  je první moment a  $\mathbf{v}$  je druhý moment.

### Výpočet chyby

Rozdíl výstupu sítě a referenčních dat je popsán chybovou funkcí křížové entropie (z angl. „Cross-Entropy“). Výpočet chyby pomocí této funkce je uveden rovnicí 7.4 [63].

$$L_i = - \sum_{c=1}^C \beta_c \cdot x_{i,c} \cdot \log(y_{i,c}) \quad (7.4)$$

kde  $L$  je chyba,  $\beta_c$  je váha třídy,  $C$  je počet tříd,  $x_{i,c}$  jsou manuálně anotovaná data (tzv. „labels“) a  $y_{i,c}$  jsou predikovaná data (výstup sítě).

Váha  $\beta_c$  je v programu nastavena pro všechny třídy na hodnotu 1. Počet tříd  $C$  pro klasifikaci je roven dvěma.

V procesu trénování sítě jsou váhy nejprve inicializovány náhodně, avšak v každé iteraci jsou tyto váhy upraveny tak, aby výsledná hodnota chybové funkce byla co nejnižší. Proces učení konvergoval po 60 iteracích, kdy v testovací sadě dat měla metoda nejvyšší přesnost a současně nejnižší chybu.

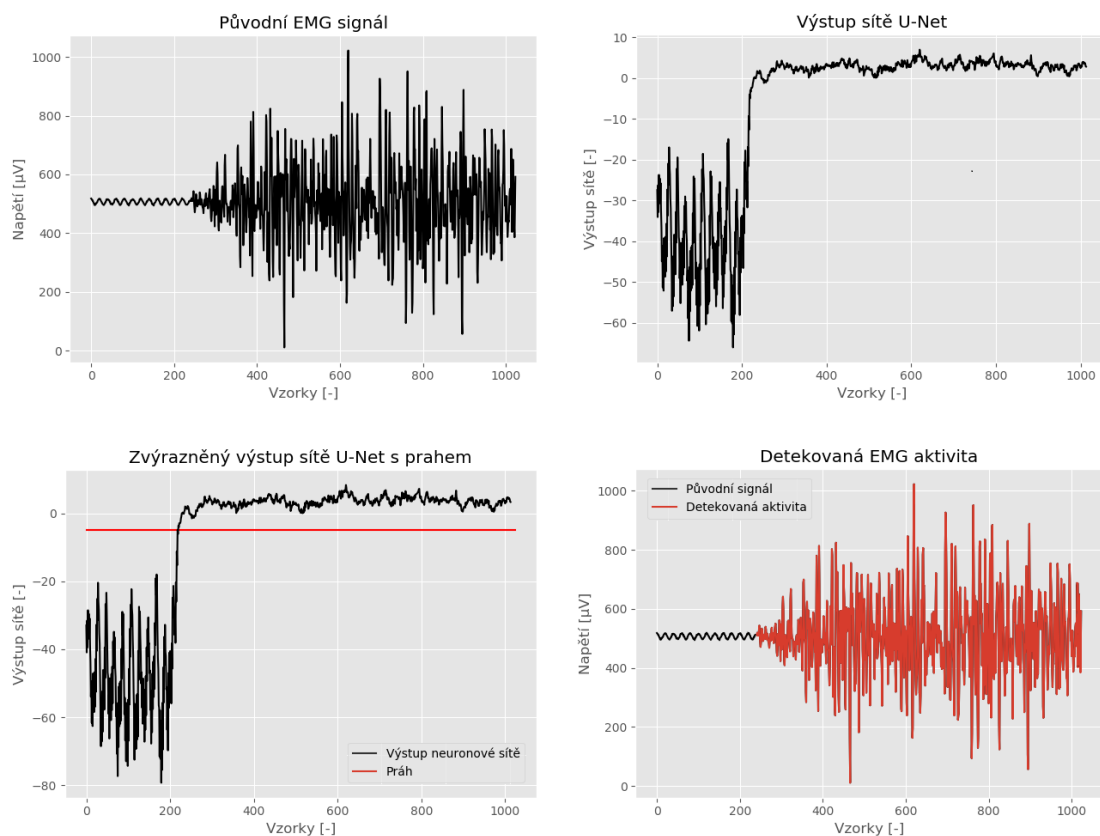
### Dropout

Při trénování sítě je ve výstupní vrstvě je zařazen „dropout“, který pomáhá redukovat vzájemné závislosti mezi neurony, čímž sníží pravděpodobnost přeučení a neuronová síť se stává robustnější. Dropout je metoda, jež vybírá náhodně neurony, které deaktivuje, tudíž se tyto neurony v dané iteraci nepodílí na procesu učení, ani na výstupu sítě [60].

### Klasifikace EMG signálu

Při učení neuronové sítě trénovací množina obsahovala více vzorků klidového signálu než vzorků signálu, kde je přítomna aktivita, tudíž neupravený výstup sítě preferoval predikci klidu. Aby byla klasifikace správná, je výstupní signál predikce aktivity vynásoben hodnotou 1.2, čímž dojde ke zvýraznění výstupu. Výsledná klasifikace (0 nebo 1) je výsledkem prahování tohoto signálu konstantní hodnotou -2. Proces je znázorněn na obrázku 7.9. Výstupem sítě je signál, v němž jsou veškeré vzorky klasifikovány do dvou kategorií (klid/aktivita), jak je znázorněno na obrázku 7.9 vpravo dole.





Obr. 7.9: Predikce aktivity v EMG signálu metodou U-Net


## Real-time detekce EMG

Signál z BITalina je načítán v oknech o velikosti 100 vzorků. Na vstupu neuronové sítě je vyžadován signál délky 512 vzorků. Jelikož je potřeba okamžitého zpracování aktuálního úseku signálu, je tento úsek připojen k předchozímu, již nasnímanému, signálu tak, aby vznikl signál požadované délky, tedy 512 vzorků.

Výstup neuronové sítě je nejpřesnější v centrální oblasti signálu, a proto je aktuálně zpracovávaný úsek vložen do středu signálu a nikoliv na jeho konec. Vstupní signál pro neuronovou síť je tedy složen ze tří částí, jak je naznačeno na obrázku 7.10.



Obr. 7.10: Vstup neuronové sítě při real-time zpracování



Obr. 7.11: Klasifikovaný signál metodou U-Net

## 8 INTERPRETACE VÝSLEDKŮ

Aktivita v EMG signálu byla detekována třemi různými algoritmy – neuronovou sítí U-Net, metodou stojového učení Support Vector Machine (SVM) a prahováním signálu zvýrazněného TKEO operátorem. V následující podkapitole jsou jednotlivé metody porovnány.

V rámci práce byla při hraní implementované hry měřena reakční doba 21 dobrovolníků. Dobrovolníci byli rozděleni na dvě základní skupiny - ženy a muži. Výsledky měření byly statisticky zpracovány v programovacím jazyce Python s využitím knihovny „SciPy“.

### 8.1 Porovnání metod zpracování signálu

Pro porovnání jednotlivých algoritmů byl vytvořen skript, který simuloval real-time detekci. Signál byl zpracováván v oknech o velikost 100 vzorků (stejně jako tomu je při načítání ze zásobníku BITalina do počítače). Takto klasifikované signály byly porovnány s manuálně anotovanými daty.

Pro vyhodnocení úspěšnosti detekce byly zvoleny dvě základní metriky: přesnost a spolehlivost detekce. Přesnost detekce je poměr správně detekovaných k celkovému počtu detekcí. Spolehlivost detekce je průměrem dvou parametrů: senzitivity a specificity. Senzitivita udává schopnost rozpoznat kontrakci svalu. Parametr udává pravděpodobnost, že aktivita svalu je predikována jako aktivita. Výpočet senzitivity udává rovnice 8.1. Specificita naopak udává schopnost rozeznat klidový signál, tedy pravděpodobnost, že klidový signál bude označen jako klid. Specificita je vypočítávána vzorcem 8.2. Výsledky jednotlivých metod jsou porovnány v tabulce 8.1.

$$\text{senzitivita} = \frac{TP}{TP + FN} \quad (8.1)$$

kde  $TP$  je počet správně označených vzorků představujících kontrakci svalu a  $FN$  je počet vzorků reprezentující klidový úsek, které byly označeny jako aktivita.

$$\text{specificita} = \frac{TN}{TN + FP} \quad (8.2)$$

kde  $TN$  je počet správně označených vzorků představujících klid svalu a  $FP$  je počet vzorků reprezentující aktivitu svalu, které byly označeny jako klid.


Při myofeedbacku je důležitý čas, potřebný pro zpracování signálu. Doba výpočtu jednoho úseku je také obsažena v tabulce porovnání metod (tabulka 8.1).

Při zpracování dat byl použit počítač se čtyř jádrovým procesorem Intel Core i5-7200U 2,5 GHz a grafickou kartou NVIDIA GeForce 940MX.

Tab. 8.1: Porovnání výsledků detekce aktivity v EMG různými metodami

Metoda	Senzitivita [%]	Specifická [%]	Přesnost [%]	Doba výpočtu úseku [ms]
U-Net	96,50	97,30	97,13	1,61
SVM	94,82	95,47	95,36	1,05
TKEO	90,54	96,19	94,71	1,18

Pro výpočet reakční doby probandů je důležitý první moment, ve kterém byla EMG aktivita detekována. Porovnání jednotlivých metod s manuálně označeným signálem je zobrazen na obrázku 8.1.



Obr. 8.1: Detekce počátku EMG aktivity jednotlivými metodami

Rozdíl mezi detekovaným začátkem EMG aktivity v porovnání s manuálně zaznačeným bodem se liší v závislosti na zvolené metodě. Při detekci s využitím

metody U-Net je průměrná chyba detekce počátku aktivity 20 ms se směrodatnou odchylkou 1,1 ms, při detekci metodou SVM je průměrná chyba rovna 12 ms se směrodatnou odchylkou 0,8 ms a chyba detekce prahováním signálu upraveným TKEO operátorem je 17 ms se směrodatnou odchylkou 1,1 ms.

Průměrná chyba detekce byla počítána pouze z úseků  $\pm 1$  sekunda v okolí reálného začátku aktivity. Ovšem v některých případech se stalo, že jedna aktivita byla detekována s nějakým přerušením, případně konec aktivity nebyl správně detekován, což je pro výpočet reakční doby nepodstatné, avšak tyto chyby ovlivnily výsledné hodnoty specifity, senzitivity a celkové přesnosti.

## 8.2 Reakční doby

V rámci práce byl nasnímán elektromyografický signál 21 dobrovolníků. Dobrovolníci bylo rozděleni na dvě skupiny - hráči počítačových her a jedinci, kteří počítačové hry nehrají. Aby nedošlo k ovlivnění výsledků věkem, byla vybrána jedna věková kategorie v rozmezí věku 24-27.

Všichni probandi měli instrukce, aby na jednotlivé podněty (změna barva semaforu a objevení se vozu záchranné služby) reagovali co nejrychleji sešlápnutím pedálu. Aby bylo možné sledovat vývoj hráče v čase, každý z uživatelů odehrál pět her. Jelikož jsou při vyhodnocení výsledků využity průměry jednotlivých reakčních časů, každá hra musela trvat déle než půl minuty, jinak záznam do statistiky nebyl započítán. Tato doba byla určena tak, aby se ve hře stihly objevit všechny podněty, u kterých byl měřen reakční čas, ale zároveň tato doba musí být krátká natolik, aby se proband během této nezapočítané hry nezdokonalil natolik, že by to ovlivnilo reakční časy v následující hře. V průběhu terapeutické hry se mohlo stát, že proband zareagoval na podnět dřív, než se objevil - například při omylných reakcích na jiný podnět ve hře. Fyziologicky není možné reagovat na podnět rychleji jak za 150 ms, tudíž aby tyto reakční časy neovlivňovaly průměrné časy, byly ze statistického vyhodnocení vyjmuty.

V práci jsou hodnoceny tři rozdílné ukazatele. Prvně jsou zpracovány rozdíly mezi jednotlivými skupinami probandů, následně rozdíly reakčních časů na různé podněty a nakonec je vyhodnocen vývoj reakčních dob jednotlivců v čase.

### Rozdíly jednotlivých skupin probandů

V prvním kroku bylo testováno normální rozložení dat, přičemž byl využit Shapirův-Wilkův test, který je vhodný i pro menší počet dat. Data některých parametrů normalitu nesplňují. Přehled využívaných statistických testů při různých

podmínkách je uveden v tabulce 8.2. Jelikož není splněno normální rozložení dat a v testované skupině je relativně nízký počet vzorků, je nutné vybrat neparametrický test. Jsou testovány dvě navzájem nezávislé skupiny dat, tudíž je pro analýzu použit dvouvýběrový nepárový test. Nejvhodnějším testem splňující předešlá kritéria je Mann-Whitney test [64]. Pro přehlednost výsledků měření byly vytvořeny podkapitoly zabývající se jednotlivými hodnocenými skupinami. Výsledky měření, ze kterých statistické zpracování dat vychází, jsou uvedeny v tabulce 8.3.

Tab. 8.2: Přehled statistických testů [64]

Data	Parametrický test	Neparametrický test
Rozložení dat	Normální	Žádné předpoklady
Počet dat	$> 30$	$< 30$
Typ srovnání	Parametrický test	Neparametrický test
Dvě skupiny dat nepárově	Nepárový t-test	Mann-Whitney test
Dvě skupiny dat párově	Párový t-test	Wilcoxon test, znaménkový test
Více skupin dat nepárově	ANOVA	Kruskal-Wallis test
Korelace	Pearsonův koeficient	Spearmanův koeficient

## Pohlaví

Z naměřených dat byly spočítány průměrné časy reakčních dob ve všech pěti hrách. Hodnoty jsou uvedeny v tabulce 8.3. Hráči byly rozděleni do dvou skupin podle pohlaví - 11 mužů a 10 žen. Z dat byl vytvořen krabicový graf porovnávající tyto dvě skupiny probandů. Graf je znázorněn na obrázku 8.2. Mezi skupinou mužů a žen byl testován statistický rozdíl na hladině významnosti 0,05. P-hodnota Mann-Whitneyho testu je rovna hodnotě 0,09, tudíž statistický rozdíl mezi pohlavími nebyl prokázán.

## Hráči počítačových her

U probandů bylo zjištěno, zda hrají, nebo nehrají počítačové (PC) hry. Celkem 12 dobrovolníků běžně hraje PC hry a 9 nikoliv. Byl vytvořen krabicový graf porovnávající tyto dvě skupiny probandů, jež je uveden na obrázku 8.3. Na hladině významnosti 0,05 byl testován rozdíl průměrných reakčních časů mezi probandy hrající počítačové hry a probandy, kteří hry nehrají. P-hodnota je menší než 0,05, tudíž


existuje statisticky významný rozdíl mezi danými skupinami probandů. Jednotlivci, jež hrají hry, reagují na generované podněty ve hře rychleji, což může být dáno také tím, že jsou zvyklí na daný typ podnětů.

Tab. 8.3: Průměrné reakční doby hráčů na různé podněty


Proband	Pohlaví	Hráč her	Průměrná reakční doba [s]	Změna na zelenou [s]	Změna na červenou [s]	Záchranná služba [s]
1.	žena	NE	0,43	0,38	0,5	0,30
2.	muž	ANO	0,35	0,29	0,40	0,58
3.	muž	NE	0,49	0,47	0,48	0,42
4.	žena	NE	0,52	0,43	0,60	0,72
5.	muž	ANO	0,34	0,30	0,35	0,58
6.	žena	NE	0,42	0,39	0,44	0,69
7.	žena	NE	0,50	0,46	0,53	0,67
8.	muž	ANO	0,32	0,30	0,34	0,60
9.	muž	NE	0,39	0,34	0,40	0,68
10.	žena	NE	0,49	0,52	0,45	0,64
11.	žena	ANO	0,41	0,38	0,42	0,50
12.	muž	ANO	0,32	0,29	0,34	0,44
13.	žena	ANO	0,35	0,35	0,34	0,40
14.	žena	ANO	0,34	0,27	0,43	0,37
15.	žena	NE	0,47	0,43	0,48	0,55
16.	muž	ANO	0,45	0,31	0,53	0,68
17.	muž	ANO	0,34	0,29	0,38	0,48
18.	žena	ANO	0,37	0,33	0,41	0,53
19.	muž	ANO	0,38	0,32	0,45	0,41
20.	muž	ANO	0,45	0,31	0,53	0,68
21.	muž	NE	0,49	0,45	0,51	0,75

Skupiny mužů a žen byly následně rozděleny podle stejného kritéria - zda hrají, či nehrají PC hry. Krabicové grafy pro jednotlivé skupiny jsou znázorněny na obrázku 8.4 a 8.5. Z grafů lze vidět, že jsou patrné rozdíly mezi jedinci hrající a nehrající PC hry jak u skupiny žen, tak i u mužů. U obou pohlaví byl opět testován rozdíl na hladině významnosti 0,05, přičemž u skupiny žen p-hodnota byla 0,007 a u skupiny mužů 0,03, z čehož vyplývá, že existuje statisticky významný rozdíl

mezi skupinou jedinců hrající a nehrající počítačové hry, přičemž nezáleží jestli jsou testovou skupinou muži, nebo ženy.




Obr. 8.2: Srovnání průměrných reakčních časů u skupin probandů různého pohlaví




Obr. 8.3: Srovnání průměrných reakčních časů u skupin probandů hrajících a nehrajících počítačové hry






Obr. 8.4: Srovnání průměrných reakčních časů u skupiny žen hrajících a nehrajících počítačové hry




Obr. 8.5: Srovnání průměrných reakčních časů u mužů hrajících a nehrajících počítačové hry

V případě, že by skupiny probandů byly nejdříve rozděleny podle herních zálib, a až následně podle pohlaví, grafy by vypadaly rozdílně - viz. obrázky 8.6 a 8.7. U obou těchto skupin byl opět testován rozdíl na hladině významnosti 0,05, přičemž p-hodnoty byly podstatně vyšší, z čehož lze říci, že neexistuje statisticky významný

rozdíl mezi ženami a muži ani u skupiny jedinců hrající hry, ani u skupiny probandů nehrající hry.



Obr. 8.6: Srovnání reakční doby mezi ženami a muži u skupiny prodandů hrající počítačové hry




Obr. 8.7: Srovnání reakční doby mezi ženami a muži u skupiny prodandů nehrající počítačové hry

## Rozdíly reakčních dob na různé podněty

V terapeutické hře se objevují celkem tři různé podněty. Prvním z nich je změna barvy semaforu na zelenou barvu, přičemž v tomto okamžiku je hra pozastavena a proband se tak může soustředit pouze na změnu barvy semaforu.

Druhým, obdobným podnětem, je změna barvy semaforu na červenou barvu, avšak v této situaci hra běží a proband se soustředí nejenom na změnu barvy tohoto semaforu, ale také na protijedoucí vozidla, kterým se musí vyhýbat. Proto je předpokladem, že reakční čas při změně barvy semaforu na červenou bude delší, než při změně na zelenou.


V posledním ze zkoumaných podnětů je objevení se vozidla záchranné služby. V běžném případě jsou generována osobní vozidla, na které hráč nijak nereaguje, pouze se jim vyhýbá. Místo tohoto osobního vozu je v náhodném čase zobrazen vůz záchranné služby. Je předpokládána delší reakční doba, jelikož hráč první musí vyhodnotit o jaké vozidlo se jedná, následně si uvědomit, zda má reagovat a posléze teprve přichází samotná reakce.



Obr. 8.8: Srovnání průměrných reakčních dob při reakci na změnu barvy semaforu a zobrazení vozu záchranné služby

Průměrné reakční doby na jednotlivé podněty jsou uvedeny v tabulce 8.3. Nejprve byl u těchto dat opět proveden test normality (Shapirův-Wilkův test), přičemž data předpoklad normálního rozložení nesplnila, a proto pro testy byl opět vybrán stejný statistický test, jako v předchozích případech. Z dat byly vytvořeny krabíkové grafy porovnávající reakční časy na jednotlivé podněty. Na obrázku 8.8 je uveden graf, jež znázorňuje rozdíly mezi průměrnými reakčními dobami při reakci na změnu

barvy semaforu a zobrazení vozu záchranné služby. Doba, než probandi zareagovali na zobrazení vozu je delší, než doba reakce na změnu semaforu. Tento rozdíl byl testován na hladině významnosti 0,05. P-hodnota je menší než 0,05, což potvrzuje statistický rozdíl mezi reakčními dobami na změnu barvy semaforu a zobrazením vozu záchranné služby.



Obr. 8.9: Srovnání průměrných reakčních dob při reakci na různou změnu barvy semaforu

Jak již bylo popsáno výše, při změnách barev semaforu byly rozdílné okolnosti, a proto je předpoklad, že doba reakce při změně barvy na zelenou bude kratší, než při změně na červenou. Porovnání reakčních dob při změnách barvy znázorňuje krabicový graf na obrázku 8.9. Byl testován statistický rozdíl mezi těmito dvěma podmíněty, přičemž p-hodnota byla rovna 0,01, tudíž byl prokázán statisticky významný rozdíl mezi reakcemi při změně na červenou a na zelenou barvu semaforu.


## Vývoj reakční doby v čase

Každý z probandů odehrál pět her za podmínek, jež byly popsány výše. Výsledky jsou uvedeny v tabulce 8.4. Z každé jednotlivé hry byla spočítána průměrná reakční doba probanda. Výsledky jsou vystiženy krabicovým grafem na obrázku 8.10. Každý box reprezentuje průměrné doby jednotlivců v dané hře. Pro statistické zpracování byly provedeny testy normality (Shapirův-Wilkův test), přičemž v tomto případě data splňovala normální rozložení, což umožňuje použití parametrického testu. Jelikož je porovnávána skupina dobrovolníků v čase, je potřeba vybrat párový test. Jako nejvhodnější test splňující tato kritéria je Studentův t-test [64].


Tab. 8.4: Průměrné reakční doby hráčů během jednotlivých her

Proband			Průměrná reakční doba v dané hře [s]				
Proband	Pohlaví	Hráč her	První hra	Druhá hra	Třetí hra	Čtvrtá hra	Pátá hra
1.	žena	NE	0,44	0,45	0,44	0,41	0,40
2.	muž	ANO	0,41	0,35	0,38	0,34	0,28
3.	muž	NE	0,62	0,47	0,47	0,47	0,40
4.	žena	NE	0,74	0,64	0,39	0,46	0,38
5.	muž	ANO	0,40	0,32	0,35	0,32	0,32
6.	žena	NE	0,51	0,41	0,41	0,45	0,33
7.	žena	NE	0,54	0,48	0,52	0,51	0,44
8.	muž	ANO	0,41	0,32	0,31	0,31	0,26
9.	muž	NE	0,47	0,44	0,35	0,38	0,29
10.	žena	NE	0,59	0,50	0,52	0,44	0,41
11.	žena	ANO	0,50	0,44	0,38	0,36	0,35
12.	muž	ANO	0,39	0,33	0,31	0,28	0,30
13.	žena	ANO	0,41	0,35	0,37	0,29	0,32
14.	žena	ANO	0,42	0,40	0,32	0,31	0,27
15.	žena	NE	0,54	0,52	0,50	0,41	0,37
16.	muž	ANO	0,60	0,46	0,40	0,42	0,37
17.	muž	ANO	0,44	0,36	0,31	0,30	0,27
18.	žena	ANO	0,51	0,44	0,32	0,29	0,32
19.	muž	ANO	0,46	0,43	0,35	0,34	0,33
20.	muž	ANO	0,60	0,46	0,40	0,42	0,37
21.	muž	NE	0,67	0,56	0,50	0,39	0,35

Reakční doba je závislá na faktorech popsaných v kapitole 4.1, přičemž jedním z nich je také závislost na trénovanosti jedince. Z naměřených dat vyplývá, že čím déle hru probandi hráli, tím byla jejich reakční doba kratší. Byl zkoumán statistický rozdíl na hladině významnosti 0,05 mezi průměrnými reakčními časy vždy v po sobě následujících hrách. Statisticky významné rozdíly existovaly mezi všemi po sobě následujícími hrami, mimo dvojice hry třetí a čtvrté. V tomto případě bylo zlepšení průměrných časů menší. Největší změna průměrných reakčních časů je mezi první a druhou hrou, což je dáno především tím, že jednotlivci si v první hře nebyli jistí, na které podněty reagovat, a proto jim proces rozhodování trval delší dobu.



Obr. 8.10: Srovnání průměrných reakčních dob v jednotlivých hrách



Obr. 8.11: Krabicový graf zlepšení průměrných reakčních dob u jedinců hrajících a nehrajících hry (mezi první a poslední hrou)

Všichni dobrovolníci měli průměrný reakční čas v poslední hře lepší, než ve hře první, což bylo statisticky potvrzeno. Zlepšení u jednotlivců hrající hry je menší, než u jedinců, co hry nehrají, což vyobrazuje krabicový graf na obrázku 8.11. Byl testován rozdíl mezi těmito dvěma skupinami (jelikož se jedná o nezávislé skupiny, byl použit Mann-Whitney test), přičemž rozdíl nebyl statisticky prokázán (p-hodnota byla 0,09).

## 9 DISKUZE

Všechny metody, jež byly implementované pro detekci aktivity v EMG signálu, dosahují relativně dobrých výsledků. Metody byly testovány na manuálně anotovaných datech, přičemž postup značení dat je popsán v kapitole 7.4.

### 9.1 Dosažené parametry snímání

Parametry snímání signálu jsou ovlivněny především parametry použitého zařízení - BITalina.

Rozsah užitečných frekvencí signálu leží v pásmu do 500 Hz, tudíž z Nyquistova teorému (rovnice 1.3) vychází, že při zpracování signálu je potřebné zvolit minimální vzorkovací frekvenci 1000 Hz, což je zároveň nejvyšší možná vzorkovací frekvence, jež BITalino umožňuje. Při snímání signálů byla tedy zvolena vzorkovací frekvence 1000 Hz, což je pro zpracování dostačující. V případě, že BITalino umožňovalo vyšší vzorkovací frekvenci, mohlo by být dosaženo vyšší přesnosti při měření, tudíž i přesnějších hodnot reakční doby. Jelikož by bylo potřeba zpracovat více vzorků změnily by se výpočetní doby jednotlivých metod. Nejvíce by byla ovlivněna doba zpracování metodou využívající TKEO operátor, zatímco doba zpracování neuronovou sítí U-Net by se příliš nelišila.

Snímaný signál je ukládán do zásobníku BITalina a poté je v okně načten počítačem. Okno musí být dostatečně dlouhé, aby mělo výpovědní hodnotu, avšak nemůže být příliš dlouhé kvůli dlouhé odezvě. Aby bylo dosaženo plynulé odpovědi systému, musí být okno kratší než 256 ms. Ovšem přenos signálu, následné zpracování tohoto úseku a vyhodnocení odpovědi způsobuje další prodlevu systému, tudíž byla zvolena délka okna 100 ms.

Signál z BITalina je do počítače přenášen pomocí Bluetooth 2.0, což způsobuje zpoždění přenosu, a to v rozmezí 90-130 ms. Celkové zpoždění je tedy dáno součtem zpoždění způsobeného přenosem (90-130 ms), velikostí načítaného okna (100 ms), dobou zpracování signálu (max. 5 ms) a vykreslení příslušné odpovědi ve hře (max. 3 ms).

## 9.2 Porovnání metod detekce aktivity v signálu

Nejnižší přesnosti dosahovala metoda s využitím nelineárního operátoru TKEO s následným prahováním na základě směrodatné odchylky signálu. Přesnost této metody je 94,71 %. Jedná se o populární metodu při zpracování EMG signálů, jelikož je relativně jednoduše interpretovaná a pochopitelná.

Lepšího výsledku dosahuje metoda SVM, jež se často využívá v aplikacích, kde je nutné rozpoznávat jednotlivá gesta. Přesnost této metody při detekci aktivity v EMG signálu byla 95,36 %. Výpočetní náročnost dané metody je velmi nízká, což je při real-time využití velmi důležitý parametr. Nevýhodou dané metody je, že před samotnou klasifikací je potřeba normalizace dat, jelikož EMG signál každého probandů dosahuje různých amplitud. Tento krok je ošetřen snímáním signálu před počátkem samotné hry.

Nejvyšší přesnosti dosahuje metoda umělé inteligence, přičemž byla implementována neuronová síť s hierarchií U-Net. Přesnost detekce aktivity v signálu je 97,13%. Metoda nepotřebuje žádné předzpracování dat, ani žádnou normalizaci, jako tomu je v předešlých technikách. Nevýhodou však je, že na vstupu neuronové sítě je očekáván vždy přesný počet vzorků nebo jeho násobek, tzn. že vstupem sítě může být jak signál o délce 512 vzorků, tak i o délce 1024, ale nic mezitím. Spolehlivost segmentace na okrajích vstupního signálu je nižší, než v centrální části daného úseku. Jelikož v rámci práce je zpracováváno vždy okno o délce 100 vzorků, bylo potřeba okno doplnit o vzorky již dříve nasnímaného signálu tak, aby byla dosažena požadovaná délka signálu. Tato operace zajistila vysokou přesnost detekce, jelikož aktuálně zpracováváný úsek se vždy nacházel v centrální oblasti.

Zpracování signálu metodou U-Net trvalo s porovnáním s předchozími metody déle, což je způsobené doplňováním požadovaného okna vzorky z již dříve nasnímaného signálu, následné zpracování většího počtu vzorků a zpětná extrakce aktuálního okna (100 vzorků). V případě, že by signál měl požadovanou délku a kroky zajišťující doplnění signálu na požadovanou délku by byly vynechány, tato doba by se zkrátila téměř na polovinu, tudíž by zpracování signálu o délce 512 vzorků na daném počítači trvalo průměrně 0,8 milisekundy, což by metodu učinilo nejrychlejší.

## 9.3 Stanovení počátků aktivity v EMG signálu

Pro získání reakční doby je důležitý počáteční bod, ve kterém byla detekována EMG aktivita. Stanovením počátku aktivity v EMG signálu se zabývá více článků, přičemž jejich výsledky jsou uvedeny v tabulce 9.1. Každý z článků k vyhodnocení využívá



vlastní anotovaná data, jež se mohou velmi lišit. Signály například pochází z jiných svalů, mají jiné amplitudy a také celkově jiný poměr SNR. Vzhledem k tomu, že každý autor článku si u metod zvolil své vlastní parametry, tak i v případě, že se jedná o totožnou metodu, mohou být výsledky velmi rozdílné. Rozdílné výsledky má například metoda založená na TKEO operátoru, přičemž tyto výsledky jsou ovlivněny jak odlišností dat, tak využitou metodou pro stanovení prahové hodnoty (viz. tabulka 9.1).

Z implementovaných metod nejlepších výsledků dosahovala metoda SVM, jejíž průměrná chyba detekce počátku EMG aktivity byla 12 milisekund se směrodatnou odchylkou menší než jedna milisekunda. Pro porovnání reakčních dob mezi probandy, či při vývoji v čase je velmi důležitá především směrodatná odchylka dané chyby, která udává jak moc jsou hodnoty odchýleny od průměru. Všechny tři implementované metody detekce aktivity v signálu mají velmi nízkou směrodatnou odchylku v porovnání s výsledky metod uvedených v jiných člancích.

## 9.4 Srovnání reakčních dob v rámci hry

Při hraní terapeutické hry došlo ke zlepšení reakčních dob u všech jednotlivců, což byla statisticky prokázáno v kapitole 8. Ve článku [70] využívají terapeutickou hru založenou na myofeedbacku pro trénink reakční doby starších osob. V rámci tohoto výzkumu byla měřena síla svalu a reakční doba, přičemž probandi trénovali 2-5krát týdně po dobu tří týdnů. Reakční doba se výrazně zkrátila u obou zkoumaných skupin, přičemž u žen průměrná reakční doba klesla z 0,69 na 0,25 sekundy, což odpovídá zkrácení na 36 % původního reakčního času. U mužů se průměrná reakční doba zkrátila na 27 % původní hodnoty.

V rámci této práce bylo dosaženo snížení průměrné reakční doby z 0,50 na 0,34 sekundy, což je snížení reakční doby na 66 % původní hodnoty. Dosažené výsledky mezi těmito výzkumy byly porovnány, z čehož vyplynulo, že ve článku [70] bylo dosaženo znatelnějšího zlepšení reakční doby terapeutickou hrou, což je pravděpodobně způsobeno delší dobou trénování probandů. V případě, že by v rámci této práce bylo zkoumáno zlepšení v delším časovém období, obdobně jako tomu bylo ve výzkumu [70], pak by pravděpodobně bylo dosaženo také většího zlepšení reakční doby dobrovolníků.

Tab. 9.1: Porovnání metod pro stanovení počátků aktivity v EMG signálu

Článek	Název/princip metody	Průměrná chyba [ms]	Směrodatná odchylka chyby [ms]
[65]	Hodges (Prahování)	122,15	67,98
[65]	Li (TKEO)	107,20	58,00
[65]	Bonato (Dvojité prahování)	51,95	15,80
[65]	Gaussian mixture model	35,85	5,31
[54]	Hodges (Prahování)	-7,10	11,80
[54]	Abbink (Prahování)	8,80	10,40
[54]	Bonato (Dvojité prahování)	4,00	7,50
[54]	Likelihood-ratio detektor - step	4,20	5,00
[54]	Likelihood-ratio detektor - ramp	0,20	5,40
[54]	Lidierth (Prahování)	0,10	11,10
[54]	Statistické rozhodování	0,60	3,60
[66]	Prahování surového EMG	41,02	35,74
[66]	Likelihood-ratio detektor	11,28	7,55
[66]	Vlnková transformace	43,11	27,75
[66]	TKEO	19,06	24,78
[67]	Vlnková transformace	6,50	6,50
[67]	TKEO	<19,00	<3,00
[67]	Gaussian mixture model	<5,00	<3,00
[67]	Dvojité prahování	<3,00	<2,00
[69]	Průchody nulou	12,30	neuvedeno
[68]	Prahování	229,00	356,00
[68]	TKEO	40,00	99,00
Veselá, Hesko	TKEO	17,00	1,10
Veselá, Hesko	SVM	12,00	0,80
Veselá, Hesko	Neuronová síť U-Net	20,00	1,10

# Závěr

Diplomová práce se zabývá snímáním a zpracováním elektromyografického signálu za účelem měření reakční doby. Úvodní část práce se zabývá teorií, nejprve je popsán princip vzniku EMG signálu a jeho základní vlastnosti. Práce objasňuje principy biofeedbacku se zaměřením na myofeedback, současně je shrnuto využití biologické zpětné vazby a účinnost této terapie pro různá onemocnění. Pro motivaci pacientů se velmi často využívají terapeutické hry, jež biologický signál určitým způsobem vizualizují. V rámci teoretické části je zpracován přehled her, přičemž na základě této analýzy byla následně v praktické části navržena a implementována závodní terapeutická hra ovladatelná svalovou aktivitou.

Pro detekci aktivity v EMG signálu lze využít nespočet různých metod. V teoretické části práce jsou jednotlivé přístupy stručně popsány se zaměřením na metody strojového učení a umělé inteligence. Tyto metody se v posledních letech dostávají do popředí především při zpracování dvourozměrných signálů. V rámci práce byly aplikovány tyto metody pro klasifikaci jednorozměrného signálu.

V rámci praktické části byly naprogramovány celkem tři různé metody pro detekci aktivity v EMG signálu - metoda založená na prahování signálu upraveného TKEO operátorem, metoda strojového učení SVM (Support Vector Machine) a metoda umělé inteligence - konvoluční neuronová síť s hierarchií U-Net. Výsledky detekce jednotlivými metodami jsou srovnány a následně diskutovány, přičemž nejvyšší přesnosti (97,13 %) je dosaženo segmentací signálu neuronovou sítí.

Vytvořený program umožňuje hraní hry se současným snímáním signálu a neprodleným zpracováním daného úseku signálu, na základě čehož je hra ovladatelná svalovou aktivitou. V rámci implementované hry je možný výběr metody, kterou bude signál zpracováván, avšak defaultně je díky svým výsledkům nastaveno zpracování neuronovou sítí U-Net. Zdrojový kód je ke stažení na úložišti GitHub.

Do hry byly implementovány různé objekty, u kterých byla hodnocena reakční doba probanda. Konkrétně se jedná o implementaci semaforu a vozu záchranné služby. Reakční doba je ovlivněna velkým množstvím faktorů, jejich přehled je uveden v kapitole 4.1.

V rámci praktické části byl nasnímán EMG signál 21 dobrovolníků při hraní implementované hry. Výsledky byly statisticky zpracovány, přičemž lze říci, že probandi, jež jsou zvyklí hrát počítačové hry mají kratší reakční dobu než probandi, jež hry nehrají. Po hraní navržené hry, konkrétně po pěti hrách, došlo k výraznému zlepšení všech dobrovolníků. Průměrné zlepšení reakční doby probandů bylo o 34 %.

# Literatura

- [1] REAZ, M. B. I., M. S. HUSSAIN a F. MOHD-YASIN. *Techniques of EMG signal analysis: detection, processing, classification and applications*. Biological Procedures Online. 2006, 8(1), 11-35 [cit. 2019-10-01]. DOI: 10.1251/bpo115. ISSN 1480-9222
- [2] KONRAD, Peter. *The ABC of EMG. A Practical Introduction to Kinesiological Electromyography*. 1. [cit. 2019-10-01]. ISBN 0-9771622-1-4
- [3] ŠIMURDA, Jiří. *Biofyzika*. Brno: Fakulta elektrotechniky a komunikačních technologií, VUT Brno, 2007. p. 59 - 67. [cit. 2020-03-10].
- [4] SCHWARTZ, Mark, ed. *EMG Methods for Evaluating Muscle and Nerve Function: Location of Electrodes in Surface EMG*. InTech, 2012 [cit. 2019-03-10]. DOI: 10.5772/1465. ISBN 978-953-307-793-2.
- [5] KOLÁŘ, Radim. *Lékařská diagnostická technika*. Brno: Fakulta elektrotechniky a komunikačních technologií, VUT Brno, 2007. [cit. 2019-03-10].
- [6] HERMENS, Hermie J., Bart FRERIKS, Roberto MERLETTI, Dick Stegeman, Joleen Blok, Günter Rau, Cathy DISSELHORST-KLUG a Göran HÄGG. *European Recommendations for Surface ElectroMyoGraphy: Results of the SENIAM project. SENIAM*. 1999 [cit. 2020-01-09]. ISBN 90-75452-15-2.
- [7] HARABIŠ, Vratislav. *4 - Elektromyografie: MDBE*. Brno: Fakulta elektrotechniky a komunikačních technologií, VUT Brno. [cit. 2019-03-10].
- [8] KOZUMPLÍK, Jiří. *Zpracování biologických signálů (AABS): 12*. Brno: Fakulta elektrotechniky a komunikačních technologií, VUT Brno, 2007. [cit. 2019-03-10].
- [9] DE LUCA, Carlo J. *Surface electromyography: detection and recording*. DelSys Incorporated, 2-10, 2002 [cit. 2019-10-04].
- [10] CHOWDHURY, Rubana, Mamun REAZ, Mohd ALI, Ashrif BAKAR, Kalavani CHELLAPPAN a Tae CHANG. *Surface Electromyography Signal Processing and Classification Techniques*. *Sensors*. 2013, 13(9), 12431-12466 [cit. 2019-05-10]. DOI: 10.3390/s130912431. ISSN 1424-8220.
- [11] YUCHA, Carolyn a Doil MONTGOMERY. *Evidence-Based Practice in Biofeedback and Neurofeedback*. Las Vegas: University of Nevada, 2008 [cit. 2019-10-05]. ISBN 1-887114-19-X.

- [12] FRANK, Dana, Lamees KHORSHID, Jerome KIFFER, Christine MORAVEC a Michael McKee. *Biofeedback in medicine: who, when, why and how?* Mental Health in Family Medicine. 7. 85-91., 2010. [cit. 2019-10-05].
- [13] ORTIZ-VIGON URIARTE, Inigo, Begonya GARCIA-ZAPIRAIN a Yolanda GARCIA-CHIMENO. Game Design to Measure Reflexes and Attention Based on Biofeedback Multi-Sensor Interaction. *Sensors*. 2015, 15(3), 6520-6548 [cit. 2019-10-05]. DOI: 10.3390/s150306520. ISSN 1424-8220.
- [14] GIGGINS, Oonagh M, Ulrik PERSSON a Brian CAULFIELD. Biofeedback in rehabilitation. *Journal of NeuroEngineering and Rehabilitation*. 2013, 10(1) [cit. 2019-10-05]. DOI: 10.1186/1743-0003-10-60. ISSN 1743-0003.
- [15] *MED-EL Medical Electronics* 2020, [online]. [cit. 2020-03-05]. Dostupné z: <https://stiwell.medel.com/en/products/stiwell-electrotherapy/stiwell-biofeedback-training>
- [16] GHASSEMI, Mohammad, Rajiv RANGANATHAN, Alex BARRY, K. TRIAN-DAFILOU a Derek KAMPER. Introduction of an EMG-Controlled Game to Facilitate Hand Rehabilitation After Stroke. IBÁÑEZ, Jaime, José GONZÁLEZ-VARGAS, José María AZORÍN, Metin AKAY a José Luis PONS, ed. *Converging Clinical and Engineering Research on Neurorehabilitation II*. Cham: Springer International Publishing, 2017, 2017-10-13, s. 451-455 [cit. 2019-10-06]. Biosystems & Biorobotics. DOI: 10.1007/978-3-319-46669-9\_75. ISBN 978-3-319-46668-2.
- [17] *Rehab-Robotics* [online]. [cit. 2019-10-05]. Dostupné z: <http://www.rehab-robotics.com/>
- [18] PRAHM, Cosima, Ivan VUJAKLIJA, Fares KAYALI, Peter PURGATHOFER a Oskar C ASZMANN. Game-Based Rehabilitation for Myoelectric Prosthesis Control. *JMIR Serious Games*. 2017, 5(1) [cit. 2019-10-06]. DOI: 10.2196/games.6026. ISSN 2291-9279.
- [19] JIRAYUCHAROENSAK, Suwicha, Pasin ISRASENA, Setha PAN-NGUM, Solaphat HEMRUNGROJN a Michael MAES. A game-based neurofeedback training system to enhance cognitive performance in healthy elderly subjects and in patients with amnesic mild cognitive impairment. *Clinical Interventions in Aging*. 2019, 14, 347-360 [cit. 2019-10-06]. DOI: 10.2147/CIA.S189047. ISSN 1178-1998.

- [20] CONVERSE, Hayes, Teresa FERRARO, Daniel JEAN, et al. An EMG biofeedback device for video game use in forearm physiotherapy. In: *2013 IEEE SENSORS*. IEEE, 2013, 2013, s. 1-4 [cit. 2019-10-06]. DOI: 10.1109/ICSENS.2013.6688474. ISBN 978-1-4673-4642-9.
- [21] TABOR, Aaron, Scott BATEMAN, Erik SCHEME, David R. FLATLA a Kathrin GERLING. Designing Game-Based Myoelectric Prosthesis Training. In: *Proceedings of the 2017 CHI Conference on Human Factors in Computing Systems - CHI '17*. New York, New York, USA: ACM Press, 2017, 2017, s. 1352-1363 [cit. 2019-10-08]. DOI: 10.1145/3025453.3025676. ISBN 9781450346559.
- [22] *RehaCom* [online]. [cit. 2019-10-08]. Dostupné z: <https://www.rehacom.com/packages-modules/training-modules.html>
- [23] BENGACEMI, H., A. MESLOUB, A. OULDALI a K. ABED-MERAIM. Adaptive Linear Energy Detector based on onset and offset electromyography activity detection. In: *2017 6th International Conference on Systems and Control (ICSC)*. IEEE, 2017, 2017, s. 409-413 [cit. 2019-10-13]. DOI: 10.1109/ICoSC.2017.7958651. ISBN 978-1-5090-3960-9.
- [24] BONATO, P., T. D'ALESSIO a M. KNAFLITZ. A statistical method for the measurement of muscle activation intervals from surface myoelectric signal during gait. *IEEE Transactions on Biomedical Engineering*. 45(3), 287-299 [cit. 2019-10-13]. DOI: 10.1109/10.661154. ISSN 00189294.
- [25] MATEUSZ, Magda. *EMG onset detection – development and comparison of algorithms*. Karlskrona Sweden, 2015. Blekinge Institute of Technology. [cit. 2019-10-13].
- [26] SOLNIK, Stanislaw, Patrick RIDER, Ken STEINWEG, Paul DEVITA a Tibor HORTOBÁGYI. Teager–Kaiser energy operator signal conditioning improves EMG onset detection. *European Journal of Applied Physiology*. 2010, 110(3), 489-498 [cit. 2019-10-22]. DOI: 10.1007/s00421-010-1521-8. ISSN 1439-6319.
- [27] MERLO, A., D. FARINA a R. MERLETTI. A fast and reliable technique for muscle activity detection from surface EMG signals. *IEEE Transactions on Biomedical Engineering*. 2003, 50(3), 316-323 [cit. 2019-10-22]. DOI: 10.1109/T-BME.2003.808829. ISSN 0018-9294.
- [28] ZHANG, Xu a Ping ZHOU. Filtering of surface EMG using ensemble empirical mode decomposition. *Medical Engineering & Physics*. 2013, 35(4), 537-542 [cit. 2019-10-22]. DOI: 10.1016/j.medengphy.2012.10.009. ISSN 13504533.

- [29] SUBASI, Abdulhamit a M. Kemal KIYMIK. Muscle Fatigue Detection in EMG Using Time–Frequency Methods, ICA and Neural Networks. *Journal of Medical Systems*. 2010, 34(4), 777-785 [cit. 2019-10-22]. DOI: 10.1007/s10916-009-9292-7. ISSN 0148-5598.
- [30] *DeepLearning Academy: Artificial Intelligence vs. Machine Learning vs. Deep Learning*. [cit. 2019-12-08]. Dostupné z: <https://www.deeplearning-academy.com/p/ai-wiki-machine-learning-vs-deep-learning>
- [31] LECUN, Yann, Yoshua BENGIO a Geoffrey HINTON. Deep learning. *Nature*. 2015, 521(7553), 436-444 [cit. 2019-10-22]. DOI: 10.1038/nature14539. ISSN 0028-0836.
- [32] LEAL, Nallig, Esmeide LEAL a German SANCHEZ. Marine vessel recognition by acoustic signature. *Journal of Engineering and Applied Sciences*. 2015. [cit. 2019-10-22]. ISSN 1819-6608.
- [33] RUSSO, Rodrigo E., Juana G. FERNÁNDEZ a Raúl R. RIVERA. Algorithm of Myoelectric Signals Processing for the Control of Prosthetic Robotic Hands. *Journal of Computer Science and Technology*. 2018, 18(01) [cit. 2019-001-26]. DOI: 10.24215/16666038.18.e04. ISSN 1666-6038.
- [34] NEGI, Sachin, Yatindra KUMAR a V. M. MISHRA. Feature extraction and classification for EMG signals using linear discriminant analysis. In: *2016 2nd International Conference on Advances in Computing, Communication, & Automation (ICACCA) (Fall)*. IEEE, 2016, 2016, s. 1-6 [cit. 2020-05-23]. DOI: 10.1109/ICACCAF.2016.7748960. ISBN 978-1-5090-3480-2.
- [35] *The Complete Guide to Artificial Neural Networks: Concepts and Models: Perceptron and Multilayer Perceptron—the Foundation of Neural Networks*. [online]. [cit. 2019-12-30]. Dostupné z: <https://missinglink.ai/guides/neural-network-concepts/complete-guide-artificial-neural-networks/>
- [36] ZURADA, Jacek M. *Introduction to artificial neural systems*. St. Paul: West, c1992. ISBN 0-314-93391-3.
- [37] NASSIF, Ali Bou, Ismail SHAHIN, Imtinan ATTILI, Mohammad AZZEH a Khaled SHAALAN. Speech Recognition Using Deep Neural Networks: A Systematic Review. *IEEE Access*. 2019, 7, 19143-19165 [cit. 2020-01-22]. DOI: 10.1109/ACCESS.2019.2896880. ISSN 2169-3536.

- [38] YUNG, Jessica. *Explaining Tensorflow Code for a Convolutional Neural Network* [cit. 2019-12-08]. Dostupné z: <https://www.jessicayung.com/explaining-tensorflow-code-for-a-convolutional-neural-network/>
- [39] LU, Le, Yefeng ZHENG, Gustavo CARNEIRO a Lin YANG, ed. *Deep Learning and Convolutional Neural Networks for Medical Image Computing*. Cham: Springer International Publishing, 2017 [cit. 2020-05-15]. Advances in Computer Vision and Pattern Recognition. DOI: 10.1007/978-3-319-42999-1. ISBN 978-3-319-42998-4.
- [40] KIRANYAZ, Serkan, Turker INCE, Osama ABDELJABER, Onur AVCI a Moncef GABBOUJ. 1-D Convolutional Neural Networks for Signal Processing Applications. In: *ICASSP 2019 - 2019 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP)*. IEEE, 2019, 2019, s. 8360-8364 [cit. 2020-01-22]. DOI: 10.1109/ICASSP.2019.8682194. ISBN 978-1-4799-8131-1.
- [41] ZHAI, Xiaolong, Beth JELFS, Rosa H. M. CHAN a Chung TIN. Self-Recalibrating Surface EMG Pattern Recognition for Neuroprosthesis Control Based on Convolutional Neural Network. *Frontiers in Neuroscience*. 2017, 11 [cit. 2020-01-23]. DOI: 10.3389/fnins.2017.00379. ISSN 1662-453X.
- [42] BRENNER, Eli a Jeroen B. J. SMEETS. How Can You Best Measure Reaction Times? *Journal of Motor Behavior*. 2018, 51(5), 486-495 [cit. 2020-01-24]. DOI: 10.1080/00222895.2018.1518311. ISSN 0022-2895.
- [43] DAVRANCHE, Karen a Michel AUDIFFREN. A Chronometric and Electromyographic Approach to the Effect of Exercise on Reaction Time. MCMORRIS, Terry, Phillip D. TOMPOROWSKI a Michel AUDIFFREN, ed. *Exercise and Cognitive Function*. Chichester, UK: John Wiley & Sons, 2009, s. 153-159 [cit. 2020-04-05]. DOI: 10.1002/9780470740668.ch7. ISBN 9780470740668.
- [44] Sway Medical Reaction Time. In: *Sway Medical* [online]. [cit. 2020-04-05]. Dostupné z: <https://swaymedical.com/reports/sway-medical-reaction-time>
- [45] BRADÁČ, Albert. *Soudní inženýrství*. Brno: CERM, 1999, 725 s. : il., tab. [cit. 2020-01-09]. ISBN 80-7204-133-9.
- [46] CINAZ, Burcu, Bert ARNRICH a Gerhard TRÖSTER. Monitoring of Cognitive Functioning by Measuring Reaction Times with Wearable Devices. In:



- Proceedings of the 5th International ICST Conference on Pervasive Computing Technologies for Healthcare*. IEEE, 2011, 2011, s. - [cit. 2020-01-22]. DOI: 10.4108/icst.pervasivehealth.2011.246012. ISBN 978-1-936968-15-2.
- [47] KOSINSKI, Robert J. *A Literature Review on Reaction Time*. 2013, 1-19 [cit. 2019-10-10].
- [48] NG, Annie W.Y. a Alan H.S. CHAN. Finger Response Times to Visual, Auditory and Tactile Modality Stimuli. *Lecture Notes in Engineering and Computer Science*. IMECS. 2012, s. 1449-1454 [cit. 2019-10-10]. ISSN 978-988-19251-9-0.
- [49] WOODS, David L., John M. WYMA, E. William YUND, Timothy J. HERRON a Bruce REED. Factors influencing the latency of simple reaction time. *Frontiers in Human Neuroscience*. 2015, 9 [cit. 2020-01-22]. DOI: 10.3389/fnhum.2015.00131. ISSN 1662-5161.
- [50] SHELTON, Jose a Gideon Praveen KUMAR. Comparison between Auditory and Visual Simple Reaction Times. *Neuroscience and Medicine*. 2010, 01(01), 30-32 [cit. 2020-01-23]. DOI: 10.4236/nm.2010.11004. ISSN 2158-2912.
- [51] ABBASI-KESBI, Reza, Hamidreza MEMARZADEH-TEHRAN a M. Jamal DEEN. Technique to estimate human reaction time based on visual perception. *Healthcare Technology Letters*. 2017, 4(2), 73-77 [cit. 2020-01-22]. DOI: 10.1049/htl.2016.0106. ISSN 2053-3713.
- [52] RADEBOLD, Andrea, Jacek CHOLEWICKI, Manohar M. PANJABI a Tushar Ch. PATEL. Muscle Response Pattern to Sudden Trunk Loading in Healthy Individuals and in Patients with Chronic Low Back Pain. *Spine*. 2000, 25(8), 947-954 [cit. 2020-02-22]. DOI: 10.1097/00007632-200004150-00009. ISSN 0362-2436.
- [53] BUCSUHAZY, Katerina, Veronika SVOZILOVA, Marek SEMELA, Ivo STANA a Olga GRUBEROVA. Analysis of Driver Reaction During Braking and Avoidance Maneuver. *IOP Conference Series: Materials Science and Engineering*. 2019, 603 [cit. 2020-01-22]. DOI: 10.1088/1757-899X/603/4/042085. ISSN 1757-899X.
- [54] STAUDE, Gerhard, Claus FLACHENECKER, Martin DAUMER a Werner WOLF. Onset Detection in Surface Electromyographic Signals: A Systematic Comparison of Methods. *EURASIP Journal on Advances in Signal Processing*. 2001, 2001(2) [cit. 2020-01-28]. DOI: 10.1155/S1110865701000191. ISSN 1687-6180.

- [55] KURODA, Yoshihiro, Ilana NISKY, Yuki URANISHI, Masataka IMURA, Allison M. OKAMURA a Osamu OSHIRO. Novel algorithm for real-time onset detection of surface electromyography in step-tracking wrist movements. In: *2013 35th Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*. IEEE, 2013, 2013, s. 2056-2059 [cit. 2020-02-02]. DOI: 10.1109/EMBC.2013.6609936. ISBN 978-1-4577-0216-7.
- [56] *BITalino (r)evolution*. [online]. [cit. 2019-10-08]. Dostupné z: <https://bitalino.com/en/hardware>
- [57] *Arduino* [online]. [cit. 2019-10-22]. Dostupné z: <https://www.arduino.cc/>
- [58] SOUZA, Ronan. *GitHub* GitHub [online]. [cit. 2019-12-12]. Dostupné z: [https://github.com/RonnanSouza/need\\_py\\_speed\\_game](https://github.com/RonnanSouza/need_py_speed_game)
- [59] YUAN, LI, JIANG, et al. MU R-CNN: A Two-Dimensional Code Instance Segmentation Network Based on Deep Learning. *Future Internet*. 2019, 11(9) [cit. 2020-02-22]. DOI: 10.3390/fi11090197. ISSN 1999-5903.
- [60] SRIVASTAVA, Nitish, Geoffrey HINTON, Alex KRIZHEVSKY a a kol. Dropout: A Simple Way to Prevent Neural Networks from Overfitting. *The Journal of Machine Learning Research*.
- [61] KINGMA, Diederik P. a Jimmy Lei BA. Adam: A Method for Stochastic Optimization. *International Conference on Learning Representations*. 2015 [cit. 2020-03-11].
- [62] BUSHAEV, Vitaly. Adam — latest trends in deep learning optimization. *Towards Data Science*. [cit. 2020-03-11].
- [63] HO, Yaoshiang a Samuel WOOKEY. The Real-World-Weight Cross-Entropy Loss Function: Modeling the Costs of Mislabeling. *IEEE Access*. 2020, 8, 4806-4813 [cit. 2020-03-22]. DOI: 10.1109/ACCESS.2019.2962617. ISSN 2169-3536.
- [64] BHALERAO, Supriya a Shraddha PARAB. Choosing statistical test. *International Journal of Ayurveda Research*. 2010, 1(3) [cit. 2020-04-03]. DOI: 10.4103/0974-7788.72494. ISSN 0974-7788.
- [65] LIU, Jie, Dongwen YING, William Z. RYMER, Ping ZHOU a Mikhail A. LEBEDEV. Robust Muscle Activity Onset Detection Using an Unsupervised Electromyogram Learning Framework. *PLOS ONE*. 2015, 10(6) [cit. 2020-04-11]. DOI: 10.1371/journal.pone.0127990. ISSN 1932-6203.

- [66] XIAOYAN LI a A.S. ARUIN. Muscle Activity Onset Time Detection Using Teager-Kaiser Energy Operator. In: *2005 IEEE Engineering in Medicine and Biology 27th Annual Conference*. IEEE, 2005, 2005, s. 7549-7552 [cit. 2020-04-11]. DOI: 10.1109/IEMBS.2005.1616259. ISBN 0-7803-8741-4.
- [67] KONTUNEN, Anton, Ville RANTANEN, Antti VEHKAOJA, et al. Low-latency EMG Onset and Termination Detection for Facial Pacing. ESKOLA, Hannu, Outi VÄISÄNEN, Jari VIIK a Jari HYTTINEN, ed. *EMBEC & NBC 2017*. Singapore: Springer Singapore, 2018, 2018-06-13, s. 1016-1019 [cit. 2020-04-11]. IFMBE Proceedings. DOI: 10.1007/978-981-10-5122-7\_254. ISBN 978-981-10-5121-0.
- [68] SOLNIK, Stanisław, Paul DEVITA, Patrick RIDER, Benjamin LONG a Tibor HORTOBÁGYI. Teager–Kaiser Operator improves the accuracy of EMG onset detection independent of signal-to-noise ratio. *Acta Bioeng Biomech*. 2008, 10(2) [cit. 2020-04-11].
- [69] BENICZKY, Sándor, Isa CONRADSEN, Oliver HENNING, Martin FABRICIUS a Peter WOLF. Automated real-time detection of tonic-clonic seizures using a wearable EMG device. *Neurology*. 2018, 90(5), e428-e434 [cit. 2020-04-14]. DOI: 10.1212/WNL.0000000000004893. ISSN 0028-3878.
- [70] YAOTHAK, Jindaporn a Pornchai PHUKPATTARANONT. Game-based EMG biofeedback system for muscle training in the elderly. *Proceedings of the 5th International Conference on Rehabilitation Engineering & Assistive Technology*. i-CREaTe, 2011, s. 1-4 [cit. 2020-04-14].

# Seznam symbolů, veličin a zkratek

<b>EMG</b>	elektromyografie
<b>sEMG</b>	povrchová elektromyografie
<b>SNR</b>	poměr signál – šum
<b>MU</b>	motorická jednotka
<b>MUAP</b>	akční potenciál motorické jednotky
<b>GUI</b>	grafické uživatelské rozhraní
<b>ms</b>	milisekunda
<b>mV</b>	milivolt
$\mu\text{V}$	mikrovolt
<b>Hz</b>	Hertz
<b>CMRR</b>	Common Mode Rejection Ratio
<b>dB</b>	decibel
<b>CNN</b>	Konvoluční neuronová síť
<b>EKG</b>	Elektrokardiografie
<b>EEG</b>	Elektroencefalografie
<b>EDA</b>	Elektrodermální aktivita
<b>EOG</b>	Elektrookulografie
<b>ACC</b>	Zrychlení
<b>LUX</b>	Osvětlení
<b>LED</b>	Elektroluminiscenční dioda
<b>mAh</b>	miliampérhodina
<b>ESC</b>	Klávesa escape
<b>SVM</b>	Support Vector Machine
<b>ADHD</b>	Attention Deficit Hyperactivity Disorder (porucha pozornosti s hyperaktivitou)
<b>EMD</b>	Empirická dekompozice signálu
<b>WT</b>	Wavelet transform (Vlnková transformace)
<b>TKEO</b>	Teager-Kaiser operátor
<b>MAV</b>	Střední absolutní hodnota
<b>RMSE</b>	Střední kvadratická hodnota
<b>VAR</b>	Rozptyl signálu
<b>MNF</b>	Průměrná frekvence
<b>SGD</b>	Stochastický pokles gradientu